

Modelování a kvantitativní analýza dynamiky mechanických vlastností umělého cévního systému

Modeling and Quantitative Dynamic Analysis of Mechanical Properties of
Artificial Blood Vessel System

Bc. Martina Babicová

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D.

Ostrava, 2021

Abstrakt

Cílem této diplomové práce je analýza, modelování a kvantitativní zhodnocení dynamiky umělého cévního systému. Analýza zahrnuje využití algoritmů pro detekci cévy z videozáznamu. V práci jsou implementované segmentační algoritmy s využitím metod nárustu oblastí, fuzzy měkkého prahování a Otsu prahování. Komparativní analýzou jsou segmentace objektivně porovnané se zlatým standardem. Výsledky této analýzy byly základem pro vytvoření optimálního segmentačního modelu cévního systému z videa. V rámci práce jsou extrahované geometrické parametry cévy (plocha, obvod, tloušťka, vlnitost) popisující její mechanické vlastnosti. Následně jsou vypočítané korelační koeficienty vyjadřující míru závislosti mezi příznaky z videa a průběhem tlakové křivky z externího senzoru. Práce také obsahuje grafické uživatelské prostředí k demonstraci segmentace a extrakce příznaků z videa.

Klíčová slova

Aorta, pulzní vlna, geometrie objektu, umělý cévní systém, Otsu prahování, Matlab

Abstract

The aim of this diploma thesis is analysis, modeling and quantitative evaluation of the dynamics of the artificial blood vessel system. The analysis contains the use of algorithms to detect a vessel from a video. The thesis implements segmentation algorithms with using methods of region growing, fuzzy soft thresholding and Otsu thresholding. The segmentation are objectively compared with the gold standard by comparative analysis. The results of this analysis were the basis for creation of optimal segmentation model of the vessel system from the video. Within the thesis were extracted geometric parameters of the blood vessel (area, perimeter, corrugation, thickness) describing its mechanical properties. Subsequently, correlation coefficients were calculated expressing degree of dependence between features from the video and course of the pressure curve from external sensor. The thesis also includes a graphical user interface to demonstrate the segmentation and features extraction from video.

Keywords

Aorta, pulse wave, object geometry, artificial blood vessel system, Otsu thresholding, Matlab

Podakovanie

Rada by som podakovala vedúcemu diplomovej práce pánovi Ing. Janovi Kubíčkov, Ph.D. za odborné vedenie, všetky konzultácie, trpezlivosť a podnetné návrhy k práci. Ďalej by som chcela podakovať svojmu manželovi a rodine za podporu.

Obsah

Zoznam použitých symbolov a skratiek	6
Zoznam obrázkov	7
Zoznam tabuliek	11
1 Úvod	12
2 Hemodynamika cievneho systému	13
2.1 Kardiovaskulárny systém	13
2.2 Hemodynamika a jej parametre	15
3 Biomechanika cievneho systému	19
3.1 Zloženie a stavba cievnej steny	19
3.2 Mechanické vlastnosti cievneho systému	20
3.3 Centrálna pulzová vlna	23
3.4 Periférna pulzová vlna	23
3.5 Parametre analýzy pulzovej vlny	23
4 Video Pletysmografia	26
4.1 Fotopletysmografia ako základ video pletysmografie	26
4.2 Video pletysmografia	26
5 Matematické metódy pre hodnotenie geometrie v obraze	31
5.1 Skalárne deskriptory	31
6 Experimentálne merania na umelom cievnom systéme	35
6.1 Merací reťazec	35
6.2 Charakteristika dát	38
7 Segmentačné algoritmy	42
7.1 Prahovanie s využitím Otsu metódy	43
7.2 Fuzzy mäkké prahovanie	43

7.3	Metóda narastania oblastí	46
7.4	Morfologické operácie	47
7.5	Komparatívna analýza segmentačných algoritmov	49
7.6	Návrh a implementácia výsledného segmentačného algoritmu	52
8	Implementácia a extrakcia príznakov z videosekvencie	55
8.1	Plocha a obvod aorty	55
8.2	Vlnitosť a distribúcia hrúbky aorty	55
9	Grafické užívateľské rozhranie	60
9.1	Načítanie videa	60
9.2	Segmentácia a extrakcia príznakov	60
10	Algoritmus korelácie mechanických vlastností ciev s tlakovou vlnou	63
10.1	Predspracovanie signálov z externých senzorov	63
10.2	Predspracovanie extrahovaných príznakov obrazu	66
10.3	Korelácia tlakovej vlny s mechanickými vlastnosťami ciev	67
11	Výsledky testovania navrhnutých algoritmov	69
11.1	Výsledky segmentačných algoritmov a komparatívnej analýzy	69
11.2	Výsledný segmentačný model	73
11.3	Výsledky extrakcie príznakov	75
11.4	Výsledky korelačného algoritmu	77
12	Záver	84
	Literatúra	86
	Prílohy	91
	Zoznam príloh	92
A	Výsledky komparatívnej analýzy	93
B	Výsledky segmentácie pri komparatívnej analýze - Otsu prahovanie	96
C	Grafické užívateľské rozhranie	97

Zoznam použitých skratiek a symbolov

BSS	– Blind Source Separation (Separácia slepého zdroja)
EMD	– Empirical Mode Decomposition (Empirická modálna dekompozícia)
cICA	– Constrained Independent Component Analysis (Obmedzená analýza nezávislých komponentov)
ICA	– Independent Component Analysis (Analýza nezávislých komponentov)
IMF	– Intrinsic mode functions (Funkcie vnútorného režimu)
IPPG	– Image Photoplethysmography (Obrazová fotopletysmografia)
MSE	– Mean squared error (Stredná kvadratická chyba)
PiCA	– Periodic Component Analysis (Periodická analýza komponentov)
PPG	– Photoplethysmography (Fotopletysmografia)
PPT	– Pulse Transit Time (Čas prechodu impulzu)
PVC	– Polyvinylchlorid
ROI	– Region of interest (oblasť záujmu)
rPPG	– remote Photoplethysmography (vzdialená fotopletysmografia)
SDC	– Sorensen–Dice coefficient (Sorensov-Dice koeficient)
SDPPG	– Second Derivatives Photoplethysmography (Druhá derivácia fotopletysmografie)
SE	– Structural element (Štrukturálny element)
SSIM	– Structural similarity index measure (Index štrukturálnej podobnosti)

Zoznam obrázkov

2.1	Anatómia srdca. Prevzaté a upravené z: [4]	14
2.2	Porovnanie prietoku krvi laminárneho prúdenia (parabolický rýchlostný profil) a turbulentného prúdenia. Prevzaté a upravené z: [2]	16
2.3	Porovnanie tlaku ku prietoku u rigidnej stený a cievnej stený. Prevzaté a upravené z: [6]	17
2.4	Krivka poddajnosti systému žíl a tepien. Prevzaté a upravené: [7]	18
3.1	Stavba cievnej stený - tepny a žily. Prevzaté a upravené z: [8]	19
3.2	Porovnanie pulzových vĺn (periférna, centrálna) u zdravého jedinca a pri stuhnutí artérie. Prevzaté a upravené z [13]	21
3.3	Pulzové vlny v rôznych častiach tela s vyznačením miesta záznamu a priebehu tlaku P a rýchlosti prúdu v. Prevzaté a upravené z: [14]	22
3.4	Parametre definované v analýze pulzových vĺn [15]	23
4.1	Experiment merania video pletysmografie. Prevzaté a upravené z: [28]	28
4.2	Závislosť dĺžky videa a korelácia rPPG a pulzného oxymetra. Prevzaté a upravené z: [28]	29
4.3	Porovnanie signálov PPG (fotopletysmografia) a SDPPG (druhá derivácia PPG). Prevzaté a upravené z: [29]	30
5.1	Parameter vertikálna a horizontálna projekcia. Prevzaté a upravené z: [36]	33
5.2	Parameter konvexnosť, v hornej časti pôvodný objekt, v dolnej časti konvexný obal. Prevzaté a upravené z: [35]	33
5.3	Parameter excentricita/ výstrednosť. Prevzaté a upravené z:[36]	33
5.4	Parameter pravoúhlosť. Prevzaté a upravené z:[35]	34
5.5	Parameter kompaktnosť. Prevzaté a upravené z: [36]	34
6.1	Merací reťazec modelu umelého cievneho systému vrátane externých senzorov. Prevzaté a upravené z: [37]	36
6.2	Fyzický model umelej aorty (vľavo) a ukážka experimentálneho merania videozáznamu (vpravo). Zdroj: vlastné.	36

6.3	Tlakový senzor ARGON DTX Plus™. Zdroj: [38]	37
6.4	Optický senzor IG-028 - princíp záznamu. Prevzaté a upravené z: [40]	38
6.5	Optický senzor IG-028 - vplyv vzdialenosti medzi prijímačom a vysielačom. Prevzaté a upravené z: [40]	38
6.6	Sada dát 1 - ukážky snímok rôznych segmentov aorty. Zdroj: vlastné.	39
6.7	Rozloženie senzorov merania 2. sady dát. Zdroj: vlastné.	40
6.8	Porovnanie RGB zložiek obrazu - snímka z videa č. 7. Zdroj: vlastné.	41
7.1	Algoritmus fuzzy c-means. Prevzaté a upravené z: [45]	44
7.2	Lichobežníková funkcia príslušnosti. Prevzaté z: [47]	45
7.3	Ukážka výpočtu priestorovej agregácie: mediánová a priemerová. Zdroj: vlastné. . . .	46
7.4	Spôsoby kontroly okolia u segmentácie narastania oblastí: a) vertikálne a horizontálne 4-okolie, b) diagonálne 4-okolie, c) 8-okolie. Prevzaté z: [48].	47
7.5	Ukážka binárnej erózie s vyznačením aktívnych prvkov (čierne bodky). Zľava a) vstupný obraz b) štruktúrny element c) výstupný obraz po erózii. Prevzaté z: [48]. .	48
7.6	Ukážka binárnej dilatácie s vyznačením aktívnych prvkov (čierne bodky). Zľava a) vstupný obraz b) štruktúrny element c) výstupný obraz po dilatácii. Prevzaté z: [48].	49
7.7	Schéma komparatívnej analýzy a jej postupu. Zdroj: vlastné.	50
7.8	Ukážka manuálnej segmentácie. Zdroj: vlastné.	50
7.9	Ukážka výsledného segmentačného algoritmu a jeho postup. Zdroj: vlastné.	53
8.1	Vzdialenostné metriky: manhattanská a euklidovská vzdialenosť. Prevzaté a upravené z: [48].	56
8.2	Výpočet kostry obrazu a následná detekcia počiatočných (resp. koncových) bodov v porovnaní so vstupným binárnym obrazom. Zdroj: vlastné.	57
8.3	Postup výpočtu distribúcie hrúbky. Zdroj: vlastné.	58
9.1	Ukážka chodu aplikácie pre časť výber, načítanie a zobrazenie videa. Zdroj: vlastné.	61
9.2	Ukážka chodu aplikácie pre časť segmentácie obrazu a extrakcie videa. Zdroj: vlastné.	61
10.1	Farebné mapovanie hodnôt korelačného koeficientu v závislosti na type vlnky a stupni dekompozície. Zdroj: vlastné.	64
10.2	Ukážka rozkladu vlnkovou transformáciou so 6 stupňami dekompozície a využitím vlnky db5. Zdroj: vlastné	65
10.3	Porovnanie natívnych signálov tlaku a hrúbky (modrá) voči signálom po filtrácii (červená). Zdroj: vlastné.	65
10.4	Porovnanie pôvodného signálu plochy pred filtráciou a po filtrácii s využitím EMD. Modrá farba je pôvodný signál, červená farba je vyfiltrovaný signál. Zdroj: vlastné .	67

11.1 Ukážka segmentácie s využitím Otsu prahovania - video č.2 (vľavo) a video č.7 (vpravo). Zdroj: vlastné.	70
11.2 Ukážka segmentácie metódou Fuzzy mäkkého prahovania - video č. 2 (vľavo) a video č. 7 (vpravo). Zdroj: vlastné.	71
11.3 Ukážka segmentácie metódou narastania oblastí - video č. 2 (vľavo) a video č. 7 (vpravo). Zdroj: vlastné.	71
11.4 Ukážka segmentácie metódou narastania oblastí a morfolologickej operácie uzavretie - video č. 2 (vľavo) a video č. 7 (vpravo). Zdroj: vlastné.	72
11.5 Výsledky korelačného koeficientu pre 4 metódy - video 7. Zdroj: vlastné	72
11.6 Ukážka výsledného segmentačného modelu - video č. 1 (vľavo) a video č. 2 (vpravo). Zdroj: vlastné.	73
11.7 Ukážka výsledného segmentačného modelu - video č. 3 (vľavo) a video č. 4 (vpravo). Zdroj: vlastné.	74
11.8 Ukážka výsledného segmentačného modelu - video č. 5 (vľavo) a video č. 6 (vpravo). Zdroj: vlastné.	74
11.9 Ukážka výsledného segmentačného modelu - video č. 7. Zdroj: vlastné.	74
11.10 Extrahovaná plocha a obvod objektu z videa (250 snímok) - video č. 1. Zdroj: vlastné.	75
11.11 Extrahovaná vlnitosť a rozptyl hrúbky objektu z videa (250 snímok) - video č. 1. Zdroj: vlastné.	75
11.12 Extrahovaná stredná hodnota hrúbky objektu z videa (250 snímok) - video č. 1. Zdroj: vlastné.	76
11.13 Extrahovaná hrúbka objektu z videa (250 snímok v bode, kde bola zistená najväčšia dynamika) - video č. 1. Zdroj: vlastné.	76
11.14 Tlak meraný v odlišných miestach aorty: modrá krivka (oblúk aorty), červená krivka (zostupná časť aorty). Zdroj: vlastné.	77
11.15 Porovnanie normalizovanej tlakovej krivky a extrahovanej plochy z obrazu. Zdroj: vlastné.	78
11.16 Porovnanie normalizovanej tlakovej krivky a extrahovanej hrúbky z obrazu v bode najväčšej dynamiky. Zdroj: vlastné.	79
11.17 Porovnanie normalizovanej tlakovej krivky a extrahovanej vlnitosti z obrazu. Zdroj: vlastné.	79
11.18 Porovnanie normalizovanej tlakovej krivky a extrahovaného obvodu z obrazu. Zdroj: vlastné.	80
11.19 Vykreslenie filtrovaných signálov opticky zmeranej hrúbky v 4 meraniach na rovnakom segmente aorty. Zdroj: vlastné.	82
11.20 Porovnanie normalizovaných signálov hrúbky z videa a optického senzora. Zdroj: vlastné.	82
11.21 Extrahovaná plocha z obrazu s fixáciou a bez fixácie snímanej aorty. Zdroj: vlastné.	83

A.1	Výsledky Sorensov-Dice koeficientu pre 4 metódy - video 7. Zdroj: vlastné	93
A.2	Výsledky koeficientu štruktúrálnej podobnosti pre 4 metódy - video 7. Zdroj: vlastné	94
A.3	Výsledky strednej kvadratickej chyby pre 4 metódy - video 7. Zdroj: vlastné	94
B.1	Ukážka segmentácie s využitím Otsu prahovania - video č. 3 (vľavo) a video č. 4 (vpravo). Zdroj: vlastné.	96
B.2	Ukážka segmentácie s využitím Otsu prahovania - video č. 5 (vľavo) a video č. 6 (vpravo). Zdroj: vlastné.	96
C.1	Grafické užívateľské rozhranie analýzy umelého cievneho systému. Zdroj: vlastné. . .	97

Zoznam tabuliek

3.1	Faktory ovplyvňujúce odrazivosť. Prevzaté a upravené z: [12]	22
6.1	Tabuľka parametrov videozáznamu. Zdroj: vlastné.	39
7.1	Interpretácia korelačného koeficientu podľa Guilforda. Prevzaté z: [51].	51
11.1	Tabuľka parametrov komparatívnej analýzy pre video č. 1. Zdroj: vlastné.	73
11.2	Tabuľka korelačných koeficientov tlakovej krivky 1 (v mieste aortálneho oblúku) a prí- znakov extrahovaných z obrazu. Zdroj: vlastné.	80
11.3	Tabuľka korelačných koeficientov tlakovej krivky 2 (v mieste zostupnej aorty) a prí- znakov extrahovaných z obrazu. Zdroj: vlastné.	81
11.4	Tabuľka korelačných koeficientov medzi hrúbkami cievy nasnímanými opticky a vi- deozáznamom. Zdroj: vlastné.	82
A.1	Tabuľka parametrov komparatívnej analýzy pre video č. 2. Zdroj: vlastné.	93
A.2	Tabuľka parametrov komparatívnej analýzy pre video č. 3. Zdroj: vlastné.	95
A.3	Tabuľka parametrov komparatívnej analýzy pre video č. 4. Zdroj: vlastné.	95
A.4	Tabuľka parametrov komparatívnej analýzy pre video č. 5. Zdroj: vlastné.	95
A.5	Tabuľka parametrov komparatívnej analýzy pre video č. 6. Zdroj: vlastné.	95
A.6	Tabuľka parametrov komparatívnej analýzy pre video č. 7. Zdroj: vlastné.	95

Kapitola 1

Úvod

Diagnostika kardiovaskulárneho systému je neoddeliteľnou súčasťou dnešnej medicíny. Podľa údajov WHO (World Health Organization) svetovej zdravotníckej organizácie každý rok zomrie na srdcovocievne choroby až 17,9 milióna ľudí, čo tvorí 31 % podiel zo všetkých úmrtí na svete [1]. Verím, že aj práve preto sa diagnostika týchto ochorení veľmi rýchlo posúva vpred. Metód, ktoré hodnotia patológie srdca a cievneho systému je veľké množstvo a na danú problematiku je možné nahliadať z viacerých uhlov. Jednou zo skúmaných oblastí kardiovaskulárnej sústavy je práve dynamika cievneho systému. V ľudskom tele sú cievy s odlišnými vlastnosťami a ich štruktúra je prispôbená účelu, ktorý cieva vykonáva.

V teoretickej časti práce sú zahrnuté poznatky ohľadom kardiovaskulárneho systému, hemodynamiky (kapitola 2) a biomechaniky (kapitola 3) cievnej stený. Táto časť je doplnená analýzou parametrov pulzovej vlny, ktorá je základnou príčinou zmien mechanických vlastností cievnej stený.

V rámci práce boli nasnímané experimentálne videá, ktoré majú určitý základ v bezkontaktnéj video pletysmografii. Rešerš používaných metód, možnosti záznamu a zhrnutie doterajších výsledkov obsahuje kapitola 4. V procese spracovania video záznamu je zahrnutá segmentácia konkrétnej oblasti (aorty) a popis geometrie objektu pomocou rôznych príznakov zhrnutých v kapitole 5.

Experimentálne merania s cieľom získať videozáznam funkcie umelého cievneho systému sú priblížené v kapitole 6. Kapitola zhŕňa informácie o modeli umelého krvného riečiska a o externých senzorocho na meranie hrúbky aorty a tlakovej krivky. Ďalšia kapitola 7 predstavuje použité segmentačné algoritmy a ich komparatívnu analýzu. Následne je v kapitole 8 priblížená extrakcia príznakov z video záznamov pre geometrický popis cievy. Modelovanie dynamiky mechanických vlastností ciev popisujú 4 základné parametre - plocha, obvod, vlnitosť a hrúbka objektu. Funkcionalita segmentácie a extrakcie príznakov je demonštrovaná vo vytvorenom grafickom užívateľskom prostredí (kapitola 9). V ďalšej kapitole 10 je skúmaná korelácia mechanických vlastností ciev s tlakovou vlnou. Táto časť práce vysvetľuje implementovaný algoritmus pre analýzu korelácie príznakov z obrazu a tlakovej krivky. Predpokladom je, že priebeh určitých príznakov v čase bude korelovať s priebehom tlakovej vlny.

Kapitola 2

Hemodynamika cievneho systému

Prvá kapitola tejto diplomovej práce prináša teoretický základ kardiovaskulárneho systému a podrobnejší rozbor hemodynamických parametrov.


2.1 Kardiovaskulárny systém

Kardiovaskulárny systém predstavuje celok zložený z dvoch hlavných častí: srdca a rozvetveného systému ciev. Transportné médium je krv zabezpečujúca mnoho dôležitých funkcií. Z pohľadu obehovej sústavy je súčasťou aj lymfatický systém, ktorý neobsahuje krv, ale v spojení s cievami vykonáva výmennú funkciu. Funkčne predstavuje srdce dve pumpy s malým (pľúcny) a veľkým (telový) krvným obehom. Obehy sú zložené zo sériovo zapojených tepien, žíl a vlásočníc. Pľúcny obeh zahŕňa výmenu plynov medzi krvou a alveolami. Telový obeh tvoria všetky cievy v orgánoch aj mimo nich okrem pľúc [2].

Srdce ako pumpa pracuje tak, že prijíma krv zo žíl pri nízkom tlaku, pri kontrakcii komôr tlak zvýši, čím dodá krvi vyššiu energiu a vytlačí krv do artérií. Prietok krvi nie je poháňaný výstupom zo srdca ako takým, ale tlakom generovaným v arteriálnom systéme. Pri určovaní prietoku krvi sa vychádza z podielu: $(\text{arteriálny tlak} - \text{venózný tlak}) / \text{cievny odpor orgánov}$ [2].

Z anatomicko-funkčného pohľadu ako ukazuje obrázok 2.1 je srdce tvorené dvomi čerpadlami (pravá a ľavá polovica srdca). Obidve čerpadlá sú duté orgány, ktoré majú steny tvorené svalovinou. Každá časť je zložená z predsieni a komory [3].

Pravá komora má v porovnaní s ľavou tenšiu stenu a menšiu hmotnosť. Tieto vlastnosti sú postačujúce pre nízkotlakový pľúcny obeh, do ktorého je privádzaná odkysličená krv cez hornú a dolnú do pravej predsieni [3].



Obr. 2.1: Anatómia srdca. Prevzaté a upravené z: [4]

2.1.1 Rozdelenie ciev z funkčného hľadiska

Z funkčného hľadiska je rozdelenie do šiestich kategórií nasledovné:

1. **Pružníkové ciev**y, ktorých úlohou je rýchly transport krvi do periférnej časti tela, tvoria veľké a stredne veľké tepny s veľmi dobrou elasticitou. Hlavne v aorte je veľmi žiadúce, aby cieva mala vysokú elasticitu a vedela premeniť nárazový prietok krvi v systole na kontinuálne prúdenie. Mechanické vlastnosti týchto ciev sa so zvyšujúcim vekom menia. Ciev sa stávajú tuhšie, kvôli zvýšenému množstvu kolagénnych vlákien [3].
2. **Rezistenčné ciev**y sa podieľajú na regulácii prietoku krvi ku tkanivám a orgánom. Patria sem 2 skupiny ciev:
 - (a) arterioly (prekapilárne rezistenčné ciev)y so silnou stenou hlavne z hladkého svalstva. Táto vlastnosť dovoľuje aby rýchlo menili prievit, a tým ovplyvňovali distribúciu minútového srdcového výdaja k orgánom. Zároveň veľkou mierou prispievajú k cievnej odpore [3].
 - (b) venuly (postkapilárne rezistenčné ciev)y oproti arteriolám prispievajú oveľa menším odporom ciev. Ich úloha je aj tak dôležitá, pretože v spolupráci s arteriolami vytvárajú hydrostatický tlak krvi v kapilárach. Práve pomerom medzi tonusom prekapilárnych a postkapilárnych rezistentných ciev je určený hydrostatický tlak, ktorý umožňuje filtráciu a resorpciu [3].
3. **Prekapilárne sfinktery** predstavujú konečné úseky prekapilárnych ciev - arteriol a ovplyvňujú veľkosť kapilárnej plochy. Konkrétne ich zúženie alebo rozťahnutie rozhoduje o počte otvorených kapilár, a tým aj o veľkosti plochy, na ktorej prebieha výmena tekutiny medzi kapilármi a intersticiom (vmedzereným tkanivom) [3].

4. **Kapiláry** zabezpečujú transfer látok z krvi do intersticiálnej tekutiny a späť. Výsledkom stavov vyššie uvedených dvoch skupín ciev (pre- a postkapilárne rezistenčné cievy a prekapilárne sfinktery) sa mení prietok kapilár. Nie sú ovplyvnené kontrakciou, ale takouto pasívnou zmenou [3].
5. **Arteriovenózne skraty** s funkciou pre rýchly prevod krvi tepenného do žilného riečiska, avšak s vynechaním kapilár. Ak sú arteriovenózne skraty otvorené, prietok tkanivom sa zvyšuje, avšak opak nastáva pri prietoku kapilármi, kde môže dôjsť až ku zastaveniu [3].
6. **Kapacitné cievy**, ako už z názvu je možné odvodiť, fungujú ako rezervoár. Táto zásoba krvi je nutná pre variabilnú distribúciu krvi v orgánoch a tkanivách. Sú to hlavne žily zabezpečujúce žilný návrat, čím priamo ovplyvňujú funkciu srdca [3].

2.2 Hemodynamika a jej parametre

Hemodynamika je označovaná ako veda zaoberajúca sa zákonitosťami, súvislosťami a princípmi prúdenia krvi. Existuje mnoho fyzikálnych veličín, ktorými je vyznačovaná a ovplyvňovaná. Čím ďalej, tým viac sa charakterizuje pomocou fyzikálnych modelov, rôznych matematických rovníc a počítačovou simuláciou. Základom ostávajú zákonitosti v krvnom obeh. V organizme sa nachádzajú cievy s rozdielnymi vlastnosťami. Ako bolo uvedené v podkapitole vyššie, funkčné rozdelenie ukazuje aj na morfológické rozdiely v skladbe ciev. Štruktúra je prispôbená účelu, ktorý cieva vykonáva [5].

Odpor krvi, tlak a prietok majú svoju analógiu v Ohmovom zákone [3]:

$$Q = \frac{\Delta P}{R}, \quad (2.1)$$

kde Q je prietok krvi, P je tlak krvi v cieve (sila, ktorou krv pôsobí na jednotku plochy cievnej steny) a ΔP predstavuje rozdiel tlakov medzi začiatkom a koncom cievy. R je periférny odpor. Ďalej budú tieto 3 parametre rozobrané zvlášť [3].

2.2.1 Odpor

Odpor, ktorý je kladený prietoku krvi závisí na cievach a kvapaline - krvi. Jeho odvodenie z Hagenovho-Poiseuilleovho zákona je vyjadrené nasledovne [5]:

$$R = \frac{8\eta L}{\pi r^4}, \quad (2.2)$$

kde R je odpor, l je dĺžka trubice, η je viskozita a r je polomer trubice. Odpor zvyšuje viskozita kvapaliny a dĺžka trubice a naopak znižuje polomer trubice. V menovateli je polomer ciev až na štvrtú mocninu, takže aj malým zmenšením r sa odpor výrazne zvýši [5].

Odpor ciev R sa nemeria priamo, ale počíta sa z hodnôt rozdielov tlaku - tlakových gradientov medzi začiatkom a koncom konkrétnej časti obehu P_1, P_2 a prietokom krvi Q podľa vzorca [5]:

$$R = \frac{P_1 - P_2}{Q}, \quad (2.3)$$

2.2.2 Prietok

Prietok vyjadruje objem krvi, ktorý pretečie naprieč prierezom cievy za jednotku času. Väčšinou sa vyjadruje v ml/s. Aj prietok je možné charakterizovať Hagenovým - Poiseuilleovým zákonom [5]:


$$Q = (P_1 - P_2) \cdot \frac{\pi}{8} \cdot \frac{1}{\eta} \cdot \frac{r^4}{l}, \quad (2.4)$$

kde P_1 , P_2 sú tlaky v mieste vtoku a výtoku, r je polomer cievy, l je dĺžka cievy a η je viskozita kvapaliny. Z rovnice vyplýva, že prietok je priamoúmerný tlakovému rozdielu a štvrtej mocnine polomeru trubice. Naopak vyššia viskozita kvapaliny a dĺžka trubice prietok znížia [5].

V artériách je prietok krvi spravidla laminárny a prúdenie sa uskutočňuje v osobitných vrstvách. Tieto vrstvy majú rozdielne rýchlosti. Ako ukazuje nasledujúci obrázok 2.2 v hornej časti (laminárne prúdenie), rýchlostný profil prietoku krvi vo väčších cievach je parabolický. V tzv. axiálnom prúde je rýchlosť prúdenia krvi najväčšia (v osi cievy) a smerom ku stenám sa znižuje. Tento jav má fyzikálny základ v zložení krvi pri stenách a v strede cievy. Pozdĺž stien je oveľa menší hematokrit a viac krvnej plazmy. Naopak v strede cievy je najviac erytrocytov [5].

Tieto vrstvy prúdiacej kvapaliny medzi sebou vytvárajú trecie sily. Vnútorne trenie vzniká nielen klzaním týchto jednotlivých vrstiev po sebe, ale aj medzi prúdiacou kvapalinou a stenou cievy. Tieto sily vyvolávajú tzv. Tangenciálne napätie [5].

V cievach sa vyskytuje nielen laminárne prúdenie. Fyziologicky sa na začiatku aorty a v malom obehú prejaví aj turbulentné prúdenie. Je tu vysoká rýchlosť, ktorou krv prúdi a väčší prievit ciev. Porovnanie a rozdiely ukazuje obrázok 2.2.



Obr. 2.2: Porovnanie prietoku krvi laminárneho prúdenia (parabolický rýchlostný profil) a turbulentného prúdenia. Prevzaté a upravené z: [2]

Pravdepodobnosť vzniku tohto prúdenia vyjadruje parameter - Reynoldovo číslo:

$$Re = \frac{v \cdot S \cdot h}{\eta}, \quad (2.5)$$

kde Re je Reynoldovo číslo, v je rýchlosť toku krvi, S je prierez cievy ($\pi \cdot r^2$), h je merná hmotnosť kvapaliny, η je viskozita kvapaliny [5].


2.2.3 Tlak

Pre prúdenie krvi v obehovej sústave je základnou podmienkou sila, ktorou krv pôsobí na stenu cievy. Tento parameter, tlak, závisí priamo úmerne od tlakového rozdielu medzi začiatkom a koncom cievy. Znovu je možné uplatniť vzťah z Ohmovho zákona [5]:

$$Q = \frac{P_1 - P_2}{R}, \quad (2.6)$$

kde Q je tlak, v čitateli sa nachádza tlakový rozdiel a v menovateli odpor.

Cievy predstavujú elastické trubice, v ktorých vzťah medzi prietokom a tlakom nemá lineárnu charakteristiku ako ukazuje obrázok 2.3. Táto charakteristika má určitý prah, pod ktorým už krv prestáva prúdiť. Určuje hranicu, kedy tlak ešte nie je nulový, avšak nedostatočný na pretlačenie erytrocytov cez kapiláry. Priemerná hodnota kritického uzatváracieho tlaku je 2,67 kPa (20 mmHg) [5].



Obr. 2.3: Porovnanie tlaku ku prietoku u rigidnej steny a cievnej steny. Prevzaté a upravené z: [6]

2.2.4 Rýchlosť prúdu

Rýchlosť prúdu je udávaná v jednotkách dĺžky za jednotku času ($v = l/t$), na rozdiel od prietoku, ktorý je určený ako objem za čas. Tento hemodynamický parameter je priamo úmerný prietoku a nepriamo úmerný prierezu cievy [5]:

$$v = \frac{Q}{S}, \quad (2.7)$$

kde v je rýchlosť prúdu, Q je prietok krvi a S prierez cievy.

Pri rýchlosti prúdu kvapaliny sa uplatňuje Brenouillio princíp, ktorý vysvetľuje fakt, že súčin kolmého prierezu S a rýchlosti v za podmienok stacionárneho prúdenia kvapaliny je konštantný [5]:

$$k = S \cdot v. \quad (2.8)$$

Z rovnice vyplýva, že čím menší je prierez, tým väčšia je rýchlosť prúdenia. Prepojením rýchlosti a prúdenia krvi spomínaného vyššie, sa v tejto súvislosti tiež uplatňuje vzťah Reynoldovho čísla. Tzv. kritická rýchlosť predstavuje rýchlosť, pri ktorej dochádza ku zmene laminárneho prúdenia na turbulentné [5].

Aj keď je rýchlosť priamo úmerná prietoku, neimplikuje vysoká rýchlosť aj veľký prietok. Rozhodujúca pre zásobovanie orgánov krvou je perfúzia (objem za čas). Prietok krvi je tiež možné vypočítať zo vzťahu rýchlosti prúdenia a prierezu cievy [5]:

$$Q = v \cdot S, \quad (2.9)$$

kde Q je prietok krvi, v je rýchlosť prúdenia a S je prierez cievy.


2.2.5 Poddajnosť

Poddajnosť, tiež nazývaná compliance sa vypočíta ako podiel zmeny objemu a zmeny tlaku podľa nasledujúceho vzťahu [5]:

$$C = \frac{\Delta V}{\Delta P}, \quad (2.10)$$

kde C je poddajnosť cievy, ΔV je zmena objemu, ΔP je zmena tlaku.

Graficky sa poddajnosť vyjadruje tlakovo-objemovými krivkami ako je viditeľné na obrázku 2.4. Tento graf taktiež vyjadruje rozdielnosť poddajnosti venózneho systému (žily) a arteriálneho systému (tepny). Pri tepnách aj malá zmena objemu vyvoláva výrazne zvýšenie tlaku, avšak pri žilách aj väčšie zmeny objemu krvi nespôsobia veľké tlakové zmeny [5].



Obr. 2.4: Krivka poddajnosti systému žíl a tepien. Prevzaté a upravené: [7]


Kapitola 3

Biomechanika cievneho systému

Táto kapitola obsahuje stručný prehľad o stavbe ciev, pretože histologická stavba cievnych stien odráža hydrodynamiku celkového obehového systému. Ďalej budú predstavené mechanické vlastnosti ciev a analýza tlakovej (pulzovej) vlny.

3.1 Zloženie a stavba cievnej steny

Steny tepien sú zložené z 3 základných vrstiev ako ukazuje obrázok 3.1. Vnútoraná vrstva nazývaná tunica intima má dlaždicový endotel. Stredná vrstva, tunica media, má špirálovité usporiadanie a je tvorená hladkou svalovinou. Vonkajšia vrstva, tunica adventitia predstavuje väzivo, obsahujúce fibroblasty, elastické, kolagénové aj nervové vlákna.



Obr. 3.1: Stavba cievnej steny - tepny a žily. Prevzaté a upravené z: [8]

Funkcia vnútornej vrstvy je komunikačná (chemické signály a mechanosenzitivita). Stredná vrstva vykonáva mechanickú funkciu: ukladá časť mechanickej energie toku krvi do iných foriem energie (napríklad deformačná energia steny, deformovanie prierezu cievy pre reguláciu toku). Von-

kajšia vrstva zabezpečuje priestorovo - prepojovacu funkciu s okolím. Zároveň aj ochrannú funkciu pred preťažením cievnej steny [8, 9].

Medzi tepnami a žilami sú v stavbe určité rozdiely. Ako aj obrázok 3.1 naznačuje žily majú tenšie a poddajnejšie steny. Nízka tuhosť žilnej steny však má svoj význam pri tzv. svalovej pumpe. Je to proces, pri ktorom kostrové svalstvo v dolných končatinách stláča stenu žíl tak, že krv prúdi proti smeru pôsobenia gravitačnej sily. Vo svojej štruktúre žily obsahujú aj chlopne pre usmernenie toku krvi [8, 9].

3.2 Mechanické vlastnosti cievneho systému

Cievy v obehovej sústave majú rozdielny prierez a hrúbku steny. Priesvit aj hrúbka klesajú úmerne zväčšujúcej sa vzdialenosti od srdca smerom k periférii. Tieto parametre zároveň odpovedajú odlišným funkciám tepien. Tepny, ktoré sa nachádzajú v blízkosti srdca, sú hlavne elastické tzv. pružné vodiče. Počet elastických membrán nie je totožný. V koreni aorty sa nachádza približne 60 elastických membrán, avšak v rozvetvení už len 25 až 30. Koncové cievy - kapiláry už žiadne elastické membrány neobsahujú [9].

Na mechanické vlastnosti ciev vplýva mnoho faktorov. Vrstevnatá štruktúra a nehomogenita vrstiev, stena obsahujúca aktívne aj pasívne častice a taktiež posuvy, ktoré vedú k deformáciám. Z určitej miery sú ovplyvnené aj tlakovou vlnou, ktorej analýza a parametre sú predmetom ďalšieho rozboru [9].

3.2.1 Analýza tlakovej (pulzovej) vlny

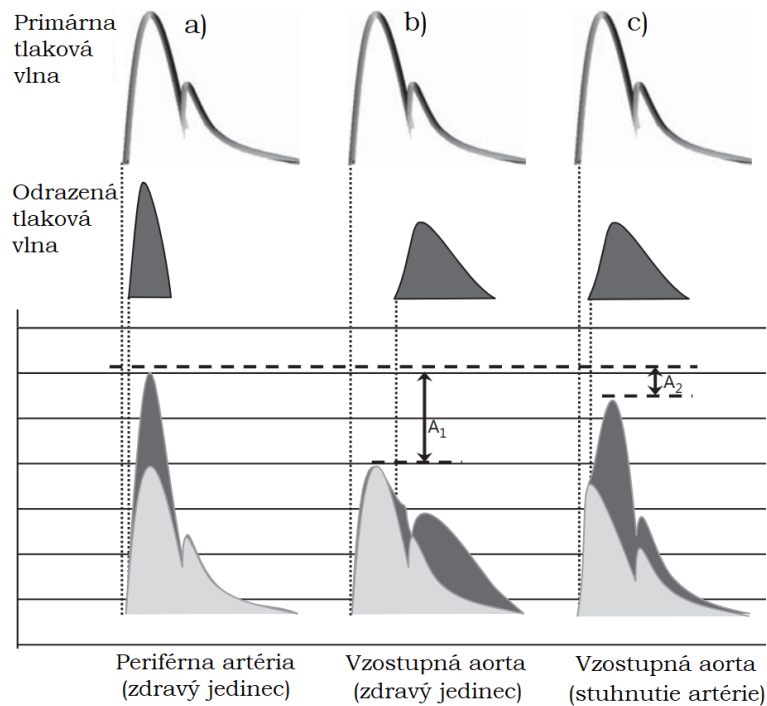
Začiatky analýzy pulzovej vlny sa objavujú už na konci 19. storočia a za hlavného priekopníka je považovaný F.A.O. Mohamed. Popísal priebeh pulzovej vlny z radiálnej tepny a porovnanie medzi ňou a pulzovou vlnou z karotídy. Vznikli teda prvé poznatky o rozdieloch medzi centrálnou a periférnou tlakovou vlnou, čo v ďalšom období viedlo k rozvoju techník pre analýzu pulzovej vlny [10].

V srdcovom cykle pri vypudení krvi z ľavej komory do aorty dochádza ku vzniku tlakovej vlny. Postupom vlny cez ďalšie cievy sú rozpínané steny tepien a vzniká pulz (tep). Toto zvýšenie tlaku a roztiahnutie ciev sa prenesie na arteriálne riečisko nezávisle na rýchlosti prúdu krvi. Rýchlosť prúdu je oveľa nižšia ako rýchlosť pulzovej vlny [6].

Na tvar pulzovej vlny, hlavne systolickej časti, pôsobí srdce zmenami rýchlosti a množstva krvi. Taktiež ju formujú elastické vlastnosti aorty a veľkých tepien. Vzhľadom na tvar krivky a miesto snímania je možné rozlíšiť tzv. centrálnu a periférnu pulzovú vlnu. Ďalším faktorom ovplyvňujúcim pulzovú vlnu sú odrazy na odstupoch z hlavného kmeňa alebo na konci krvného riečiska. Výsledná krivka predstavuje súčet prechádzajúcej vlny (tiež nazývanej primárna) a odrazenej vlny. Tento princíp približuje obrázok 3.2, kde je zobrazená centrálna aj periférna pulzová vlna. Navyše je

na obrázku ukážka vplyvu patologickej rigidnosti cievnej steny, kedy dochádza ku zmenám vlastností tkaniva [11, 12].

Na 3.2 obrázku sú porovnané 3 pulzové vlny. Princíp popísaný na začiatku tejto kapitoly ukazuje na každej časti (a, b, c) sčítanie primárnej tlakovej vlny a odrazenej vlny. K súčtu dochádza v rôznych častiach srdcového cyklu. V možnosti a) dochádza ku skorému prekrytiu týchto vln za fyziologických podmienok v periférnych cievach. Variant b) zobrazuje tlakovú vlnu snímanú vo vzostupnej aorte na subjekte s dobrými vlastnosťami stien tepien. Jedná sa teda o centrálnu pulzovú vlnu. Stretnutie vln nastáva na konci systoly a superpozícia trvá celú diastolu. Za c) ukazuje obrázok znovu snímanie vo vzostupnej aorte, avšak pri subjekte, ktorý má patologicky tuhšie artérie. Vlny sa stretávajú už v skorej systole a superpozícia týchto vln trvá celú systolickú fázu. Intervaly A_1 a A_2 poukazujú na rozdiel medzi centrálnym systolickým krvným tlakom a brachiálnym systolickým tlakom u zdravého a chorého jedinca. Ako je z obrázku viditeľné, pri zdravom človeku je interval násobne väčší [13]. Nasledujúca tabuľka 3.1 predstavuje prehľad faktorov, ktoré ovplyvňujú odrazivosť a tým aj celkový priebeh tlakovej vlny.




Obr. 3.2: Porovnanie pulzových vln (periférna, centrálna) u zdravého jedinca a pri stuhnutí artérie. Prevzaté a upravené z [13]

Tabuľka 3.1: Faktory ovplyvňujúce odrazivosť. Prevzaté a upravené z: [12]

Faktor ovplyvňujúci odrazivosť	Vplyv faktoru
kontraktilita srdca	sila a doba trvania primárnej vlny
tuhosť veľkých artérií	rýchlosť primárnej a sekundárnej vlny
rezistencia - odporové cievy	miera odrazivosti vln
dĺžka arteriálneho riečiska (srdce - miesto odrazu)	interferencia vln

Priebeh tlakovej vlny, nielen jej tvar, ale aj hodnoty tlaku a rýchlosti sú závislé od miesta snímania. Celkové rozdelenie ciev a popis ich vlastností, funkcií je vysvetlený v kapitole 2. Prehľadový obrázok 3.3 spája informácie o zmenách pulzových vln v závislosti na konkrétnom mieste záznamu. Je viditeľný trend rýchlosti, ktorá je vyššia pri periférnych pulzových vlnách [14].



Obr. 3.3: Pulzové vlny v rôznych častiach tela s vyznačením miesta záznamu a priebehu tlaku P a rýchlosti prúdu v. Prevzaté a upravené z: [14]

V ďalších podkapitolách budú detailnejšie rozobrané 2 typy pulzných vln: centrálna a periférna. Taktiež budú priblížené parametre analýzy pulzovej vlny.

3.3 Centrálna pulzová vlna

Centrálna pulzová vlna je zložená z 2 častí. Vzostupná časť je ostrá a predstavuje prechod pulzovej vlny. Zostupná časť opisuje pohyb cievnej steny po priechode vlny, krivka je postupne klesajúca. Významný zárez v tejto zostupnej časti je vyvolaný uzavretím semilunárnych chlopní. Po ich uzavretí sa od nich odrazí krv, čo sa prejaví kratším vzostupným úsekom. Následne je priebeh klesajúci. Niekedy sa prejavia aj spätné vibrácie chlopní tak, že na zostupe ramienka sú viditeľné vlny [11].


Záznam centrálnej pulzovej vlny je možné získať ivanzívne aj neinvazívne. Neinvazívne z krčnice objemovým záznamom nad cievou na povrchu kože. Invazívne intraarteriálnym katétrom a tenzometrom ako tlakový záznam [11].

3.4 Periférna pulzová vlna

Aj pri periférnych tlakových vlnách je viacero faktorov, ktoré ovplyvňujú tvar krivky. Napríklad arteriálna tuhosť, rýchlosť pulzovej vlny a už vyššie spomínaná odrazivosť vln v tabuľke 3.1. Taktiež je tvorená, podobne ako centrálna pulzová vlna, vzostupnou a zostupnou časťou. Vzostup je ostrejší ako ramienko centrálnej pulzovej vlny a tvar dikrotického zárezu a zostupnej vlny je oblejší. Záznamy periférnej vlny môžu byť z rôznych častí tela z periférnych tepien [11].

3.5 Parametre analýzy pulzovej vlny

Prehľad parametrov, ktoré sa využívajú pri analýze pulzovej vlny je zobrazený na obrázku 3.4. Obrázok zahrňuje mnoho parametrov, z čoho niektoré sa využívajú len pri analýze centrálnej tlakovej vlny, iné pri porovnaní centrálnej a periférnej pulzovej vlny. [15]



Obr. 3.4: Parametre definované v analýze pulzových vln [15]

3.5.1 Parametre analýzy centrálnej pulzovej vlny

1. Centrálny systolický tlak - maximálna hodnota tlaku v systole [$cSBP$].
2. Diastolický krvný tlak - tlak na konci diastoly [DPB].
3. Centrálny pulzový tlak - pulzný tlak, nastáva zmenou systolicko-diastolického arteriálneho tlaku. Vypočíta sa ako rozdiel systolického a diastolického tlaku [cPP].
4. Koncový systolický tlak - hodnota tlaku krvi na konci systoly [$ESPB$].
5. Časový interval odrazenej vlny - časové oneskorenie spätného priebehu vlny, ktoré zodpovedá parametru P_i [T_i].
6. Tlak v inflexnom bode - hodnota krvného tlaku v bode, kde začína superpozícia spätnej a primárnej vlny. Je to stret týchto vln [P_i].
7. Zvýšenie tlaku v dôsledku skorej odrazenej vlny. Predstavuje rozdiel centrálneho systolického tlaku a tlaku v inflexnom bode [AP].
8. Index zvýšenia uvádza percentuálne zvýšenie krvného tlaku kvôli skorej pulzovej odrazenej vlne s ohľadom na pulzný tlak. Jeho hodnota je získaná podielom AP a cPP [AIx] [15].

3.5.2 Ostatné parametre analýzy pulzovej vlny

1. Stredný arteriálny tlak - priemerné hodnoty arteriálneho tlaku vypočítané ako integrál z tlakovej krivky [MAP].
2. Stredný pulzný tlak - predstavuje rozdiel stredného arteriálneho tlaku a diastolického tlaku [MPP].
3. Stredný krvný tlak počas systoly - priemerné hodnoty arteriálneho krvného tlaku počas systolickej fáze srdcového cyklu [$MSBP$].
4. Stredný krvný tlak počas diastoly - priemerné hodnoty arteriálneho krvného tlaku počas diastolickej fáze srdcového cyklu [$MDBP$].
5. Ejekčný čas ľavej komory - trvanie systolickej fáze srdcového cyklu [$LLET$].
6. Diastolický čas - trvanie diastolickej fáze srdcového cyklu [DT].
7. Perióda srdca - trvanie srdcového cyklu, ktorého čas korešponduje s R-R intervalmi na krivke EKG [HP].
8. Diastolická časová frakcia - čas, ktorý sa vypočíta ako podiel času diastoly DT a času srdcového cyklu HP [DTF].

9. Časový index systolického tlaku je určený plochou zahrňujúcou systolickú fázu. Je rovný súčinu času systolickej fáze $LVET$ a strednému systolickému tlaku $MSPB$ [$SPTI$].
10. Časový index diastolického tlaku predstavuje plochu pod diastolickou časťou vlny krvného tlaku a získa sa vynásobením priemernej hodnoty krvného tlaku počas diastoly $MDBP$ a samotným trvaním diastoly [$DPTI$].
11. Subendokardiálny pomer životaschopnosti je index, ktorý reprezentuje rovnováhu medzi prísunom a potrebou subendokardiálneho kyslíka. Jeho hodnota je rovná pomeru predošlých 2 časových indexov $SPTI$ a $DPTI$ [15, 16].

Kapitola 4

Video Pletysmografia

4.1 Fotopletysmografia ako základ video pletysmografie

Ako hlavný ukazovateľ vitálnych funkcií srdca a cievneho systému je považovaný krvný tlak [17]. Fyziologické hodnoty maximálneho pulzného tlaku (systolický tlak) sú približne 120 mmHg a minimálny pulzný tlak v tepnách (diastolický tlak) je okolo 80 mmHg [18]. Najväčšou príčinou predčasných úmrtí v dôsledku kardiovaskulárnych chorôb je hypertenzia (vysoký krvný tlak) [19]. Jeho včasné meranie pomáha pri prevencii týchto ochorení. Tradičná oscilometrická metóda je stále využívaná pre rýchlu a jednoduchú manipuláciu [20]. Krvný tlak je meraný neinvazívne uzavretím hlavnej tepny (najčastejšie brachiálna artéria) s pneumatickou manžetou. Princíp merania je detailnejšie popísaný v publikácii [18]. Senzor, ktorý meria tento biologický parameter je v kontakte s pacientom.

Veľký význam v skríningu kardiovaskulárnych ochorení ukazuje aj fotopletysmografia (PPG). Táto metóda prináša informácie o periférnom obehu [21]. Je to neinvazívna optická technika na zisťovanie zmien objemu krvi v rôznych tkanivách. Vyžaduje svetelný zdroj na osvetlenie tkaniva a fotodetektor na snímanie zmien intenzity svetla v závislosti na zmenách prekrvenia. Základný princíp PPG sa zakladá na citlivosti rôznych optických dĺžok pre krv a tkanivo. Pre PPG senzor sa väčšinou používa svetlo červené a blízke infračervenému svetlu. Avšak objavujú sa štúdie, ktoré ukazujú na možnosti využitia zeleného svetla [22].

4.2 Video pletysmografia

Základná metóda fotopletysmografia je zatiaľ využívaná v mnohých medicínskych odvetviach, no najviac je uvádzaná pri zisťovaní zmien objemu krvi [22].

Nasledujúca štúdia [23] ukazuje viac variant umiestnenia senzorov. Nositeľné PPG senzory sa vyrábajú na báze náramku, čelových senzorov aj umiestnené na ušiach. Okrem mobilov sa dostávajú do popredia hodinky ako zariadenia s množstvom senzorov - napríklad aj Apple Watch [24], ktoré

využívajú na meranie srdcovej frekvencie fotopletysmografiu. Používajú zelené LED svetlá, ktoré sú spárované s fotodiódami, aby monitorovali množstvo krvi pretekajúce zápästím. Keď hodinky bliknú stokrát vedia vypočítať koľkokrát za sekundu srdce udrie, čiže srdcovú frekvenciu.

Od kontaktnej metódy PPG sa pozornosť presúva na metódy tzv. IPPG (image photoplethysmography) obrázová fotopletysmografia. IPPG je bezkontaktná metóda, ktorá dokáže detegovať pulzné vlny generované srdcom v závislosti na prietoku periférnej krvi [22]. Taktiež niektoré štúdie označujú túto metódu ako rPPG (remote photoplethysmography) ako vzdialená fotopletysmografia alebo taktiež bezkontaktná pletysmografia [25].

4.2.1 Princíp metódy

Jej začiatky sú podľa literatúry [22] v roku 1996 a základom je diaľkové meranie kamerou pre detekciu perfúzie v rôznych oblastiach pokožky. Dnes je možné na túto tému nájsť desiatky relevantných štúdií. Veľa z nich je zameraných na výpočet tepovej frekvencie [26, 27], avšak ešte relevantnejšie sú pre túto prácu štúdie ohľadom možnosti bezkontaktného merania PPG pri skúmaní krvných tlakov a perfúzie.

Predpoklad, že srdcové pulzácie nie sú viditeľné voľným okom, ale dajú sa zaznamenať kamerou pritiahol záujem a metóda získavala mnohé variácie. Nielen v rámci samotného experimentu ale aj spracovania videa [28].

Základom sú hodnoty jasú zaznamenané digitálnou kamerou, ktoré sa menia v čase každým úderom srdca. Táto svietivosť je odrážaná od povrchu kože. Jasové zmeny ľudské oko nedokáže zaznamenať. V mnohých vedeckých publikáciách sú opísané kroky spracovania signálu a potom porovnávané s rôznymi videami väčšinou zaznamenanými z tváre objektu [28].


4.2.2 Nastavenie experimentu

Ukážka rozmiestnenia experimentu z publikácie [28] je na nasledujúcom obrázku 4.1.

Ako ukazuje obrázok, na experiment bol použitý aj prídavný zdroj svetla pre lepšiu detekciu. Webová kamera snímala časť tela (tvár, ruku, lýtko) v drevenej konštrukcii. Podobné zostavy majú aj ďalšie experimenty napríklad v publikácii [29] objekt sedí na stoličke. V literatúre [30] je pacient v ležiacej polohe s kamerou umiestnenou nad posteľou. Taktiež sa pri väčšine meraní v spomínaných publikáciách používala referencia popri sledovaní video pletysmografiou. Najčastejšie pulzné oxymetry alebo prístroje pre snímanie EKG signálu.

Dĺžka snímania sa v rámci publikácii odlišuje. V článku [25] je doba záznamu len 10 sekúnd, v [29] 13 sekúnd, v článku [31] a [28] 30 sekúnd a v publikácii [20] 120 sekúnd. Vo väčšine článkov bola vzdialenosť kamery od tkaniva 1 meter, avšak objavili sa aj štúdie, kde bola dĺžka medzi objektom a kamerou 60 cm [32] alebo len 20 centimetrov [28].

Počet ľudí, ktorí sa zúčastnili na daných experimentoch bol v rozmedzí 10 až 60. Vekový priemer z vyššie spomenutých publikácii, ktoré zahrňovali aj túto informáciu bol približne 30 rokov v



Obr. 4.1: Experiment merania video pletysmografie. Prevzaté a upravené z: [28]


intervale od 22 do 59 rokov. Pri kamerovaní tváre bolo nutné aby participanti nemali na sebe make up. Taktiež sa v niektorých štúdiách zahrňuje aj variabilita pleti. Tón pokožky sa pohyboval od bledej bielej po tmavú hnedú [28].

4.2.3 Spracovanie video záznamu

Podľa publikácie [28] je spracovanie videa zložené z nasledujúcich hlavných krokov (konkrétne rozšírenie je podrobne vysvetlené v publikácii):

- Časovo-priestorové orezanie videa
- Výber časti tváre (pokiaľ sa napríklad jedná o záznam z pokožky na tvári)
- Priemerovanie a filtrovanie signálu
- Analýza nezávislých komponent
- Rýchla Fourierova transformácia
- Filtrovanie výkonového spektra
- Odstránenie pohybových a dýchacích artefaktov

Referencia je veľmi dôležitá pre validáciu experimentu a spracovanie záznamu. Podľa článku [28] bola korelácia počítaná medzi výsledkom z video pletysmografie a pulzným oxymetrom. V tvárovej časti bola korelácia (Spearmanov korelačný koeficient) najvyššia 0,97, na zápästí 0,5 a najmenej na lýtku 0,27. Taktiež sa v tejto publikácii objavujú zistenia, že existuje závislosť medzi počtom



Obr. 4.2: Závislosť dĺžky videa a korelácia rPPG a pulzného oxymetra. Prevzaté a upravené z: [28]

snímok a týmto korelačným koeficientom. Závislosť medzi dĺžkou videa a koreláciou rPPG (remote PPG) a pulzného oxymetra je zobrazená na obrázku 4.2 [28].


Podľa štúdie [20] sa na odhadovanie dynamických parametrov krvného obehu využíva aj analýza času priechodu impulzov (ang. Pulse Transit Time (PPT)). Namerané hodnoty krvného tlaku sú porovnávané voči neinvazívnej oscilometrickej metóde s manžetou. Metóda monitoruje nielen hodnoty tlaku krvi ale aj abnormálne rytmy srdca. V publikácii je rozobratá analýza vzťahu PTT a krvného tlaku s modelom arteriálnej stený a šírením vln v arteriálnej stene. Ak je arteriálna cieva modelovaná ako elastická trubica s tvarom valca potom možno považovať PTT za čas, počas ktorého prejde tlaková vlna určitou vzdialenosťou. Táto štúdia sa považuje ako predbežná a ponúka viacero návrhov na rozšírenie.

V publikácii [29] je na spracovanie video záznamu extrakčný algoritmus založený na analýze periodickej zložky. Analýza druhej derivácie z video pletysmografie dlane koreluje s kontaktnou pletysmografiou na prste. Je možné detegovať inflexné body ako ukazuje obrázok 4.3.

Pomer bodov d/a odráža vazokonstrikciu, ktorá je porovnávaná aj s originálnymi pomermi kontaktnej pletysmografie. Výsledky podporujú tvrdenie, že je možné vyhodnocovať aj periférne cievy z video pletysmografie [29].

V navrhovanej metóde sa využíva tzv. periodická analýza komponentov (Periodic Component Analysis - PiCA). Technika dokáže extrahovať najperiodickejšie komponenty z multikanálovej nahrávky. Záver ukazuje že navrhovaná metóda deteguje správne pulznú vlnu, ktorá nesie informácie o lokálnej regulácii v cievach [29].

Viacere štúdie z literatúry [30] používajú určitú formu tzv. Blind Source Separation (BSS) na extrakciu signálu zo záznamu RGB. Analýza nezávislých komponent (Independent Component Analysis - ICA) je jednou z najbežnejších foriem BSS. Avšak trpí určitými nedostatkami, preto sa



Obr. 4.3: Porovnanie signálov PPG (fotopletysmografia) a SDPPG (druhá derivácia PPG). Prevzaté a upravené z: [29]

niekde používa tzv. Obmedzená analýza nezávislých komponent (Constrained Independent Component Analysis-cICA). Tento prístup vyžaduje referenčný signál a znalosti zdrojov. V tejto publikácii sa tiež dáva dôraz na kvalitnú snímáciu kameru. V literatúre je uvedené, že dôležitejším faktorom dobrej extrakcie je kvalitná kamera v porovnaní s nízkou kvalitou videa kompenzovanou komplexnejšími algoritmi. V rozšírení je možné sa zaoberať extrakciou nielen fyziologickej dynamiky ciev, ale aj abnormalitami ako arytmie a fibrilácia predsiení [30].

Kapitola 5

Matematické metódy pre hodnotenie geometrie v obraze

V globálnom merítku sú príznaky (ang. features) charakteristické vlastnosti objektov. Voľba konkrétnych príznakov je závislá od spracovávaného obrazu a aplikácie [33]. Taktiež podľa literatúry [34] je možné uvažovať o príznaku ako výsledku určitého merania, ktorý kvantifikuje danú vlastnosť objektu. Po segmentácii obrazu vzniknú hranice reprezentovaného objektu.

Príznaky sa rozdeľujú podľa domény vlastnosti, ktorá je opisovaná na 2 skupiny [35]:

1. Fotometrické - zahŕňajú optické vlastnosti objektov ako napríklad jasová úroveň, rozdiel jasu medzi objektom a pozadím, jasová disperzia a ďalšie.
2. Radiometrické - prinášajú informácie o geometrických vlastnostiach objektov. Ich výpočet je odvodený z plošného rozloženia pixelov.

5.1 Skalárne deskriptory

Popis geometrie objektu v obraze je možné získať rôznymi skalárnymi deskriptormi. Základom sú pixely, ako jednotka obrazu, ktorých zoskupenia tvoria určité regióny v obraze [36]. V ďalšej časti budú jednotlivé skalárne deskriptory priblížené.

1. **Plocha/ Veľkosť** je považovaná za najjednoduchší deskriptor regiónu, ktorý je určený počtom pixelom v danom objekte. Ak je oblasť vytvorená kontúrou, výpočet predstavuje iba súčet pixelov vo vnútri hraničnej kontúry. Za predpokladu, že je hranica určená polygónom, výpočet je získaným vzťahom [34]:

$$A = \frac{1}{2} \left| \sum_{k=0}^{n-1} (x_k y_{k+1} - x_{k+1} y_k) \right|, \quad (5.1)$$

kde n je počet bodov polygónu (x_k, y_k) , pričom platí, že prvý a posledný bod sú rovnaké $(x_0, y_0) = (x_n, y_n)$. Avšak pri zisťovaní reálnej veľkosti objektu je nutné prepočítať pixeli podľa rozlíšenia. Čím je rozlíšenie väčšie, tým je veľkosť bližšie k skutočnej veľkosti [34, 36].

2. **Perimeter/Obvod** je odvodený zo súčtu euklidovských vzdialeností obrysových bodov okolo kontúry. Výsledok je priamo závislý od dĺžky hranice objektu v obraze [34].
3. **Okrúhlosť** predstavuje číslo z intervalu $<0,1>$, kde hodnota 1,0 je kruh. Matematické vyjadrenie je [34]:

$$O = \frac{4 \cdot \pi \cdot A}{p^2}, \quad (5.2)$$

kde O je okružlosť, tvorená podielom súčinu 4, π , A (plocha) a druhou mocnicou obvodu p .

4. **Feretov priemer** je možné vypočítať ako priemer kruhu, ktorý má totožnú plochu ako plocha predmetu [34].
5. **Dĺžka hlavnej osi** predstavuje dĺžku najdlhšej úsečky, ktorú je možné vytvoriť medzi akoukoľvek dvojicou obrysových bodov [34].
6. **Euler-Poincaréova charakteristika** je topologická vlastnosť založená na počte súvislých častí objektu S a počte dier v objekte. Ak sa objekt skladá z viac ako jedného regiónu platí, že tento parameter je rovný rozdielu S a N [36]:


$$\theta = S - N, \quad (5.3)$$

7. **Projekcia** sa väčšinou využíva pri spracovaní binárneho obrazu. Horizontálna a vertikálna projekcia sú definované ako [36]:

$$p_h(i) = \sum_j f(i, j), \quad p_v(j) = \sum_i f(i, j). \quad (5.4)$$

Ako ukazuje obr. 5.1 horizontálna projekcia p_h predstavuje súčet hodnôt pixelov v stĺpcoch, vertikálna projekcia p_v v riadkoch [36].

8. **Konvexnosť** určuje podobnosti medzi objektom a jeho konvexnou schránkou. Hodnota sa pohybuje v intervale 0 až 1. Pri úplne konvexných objektoch je rovná jednej. Vypočíta sa ako pomer veľkosti a plochy konvexného obalu. Nasledujúci obrázok 5.2 znázorňuje rozdiel medzi pôvodným objektom a jeho konvexným obalom [35]:




Obr. 5.1: Parameter vertikálna a horizontálna projekcia. Prevzaté a upravené z: [36]



Obr. 5.2: Parameter konvexnosť, v hornej časti pôvodný objekt, v dolnej časti konvexný obal. Prevzaté a upravené z: [35]


9. **Výstrednosť/Excentricita** sa v jednoduchšej forme vypočíta ako pomer dĺžky hlavnej a vedľajšej osi objektu. Na obrázku 5.3 je náhľad hlavnej osi A a vedľajšej osi B, ktoré sú na seba kolmé [36].



Obr. 5.3: Parameter excentricita/ výstrednosť. Prevzaté a upravené z:[36]

10. **Pravouhlosť** sa získava krokovým otáčaním objektu, tak aby bola plocha opísaného obdĺžnika najnižšia. Hodnota predstavuje pomer veľkosti a opísaného obdĺžnika. Ako približuje obrázok

5.4, čím vyšší pomer (maximálne 1), tým je väčšia pravouhlosť [35].



Obr. 5.4: Parameter pravouhlost. Prevzaté a upravené z:[35]


11. **Pretiahnutie** je charakterizované pomerom strán obdĺžnika, ktorý ohraničuje oblasť objektu. Obdĺžnik má minimálnu plochu, takže sa jedná o opísaný útvar. Za predpokladu zakriveného objektu sa pretiahnutie počíta ako pomer plochy objektu a druhej mocniny hrúbky objektu. Maximálnu hrúbku oblasti je možné zistiť ako počet krokov erózie použitých, kým objekt úplne zmizne. Potom je vzťah nasledujúci [36]:

$$pretiahnutie = \frac{S}{(2d)^2}, \quad (5.5)$$

kde S je plocha objektu a d je počet krokov erózie.

12. **Kompaktnosť** vyjadruje pomer druhej mocniny obvodu O objektu a plochy objektu S podľa nasledujúceho vzorca [36]:

$$kompaktnosť = \frac{O^2}{S}, \quad (5.6)$$



Obr. 5.5: Parameter kompaktnosť. Prevzaté a upravené z: [36]

Kapitola 6

Experimentálne merania na umelom cievnom systéme

V rámci diplomovej práce boli realizované experimentálne merania s cieľom získať videozáznam funkcie umelého cievneho systému a zároveň zaznamenať zmeny tlaku a hrúbky cievy. Vďaka modelu a senzorum, ktoré budú priblížené v tejto kapitole, bolo možné monitorovať dynamiku tohto systému.

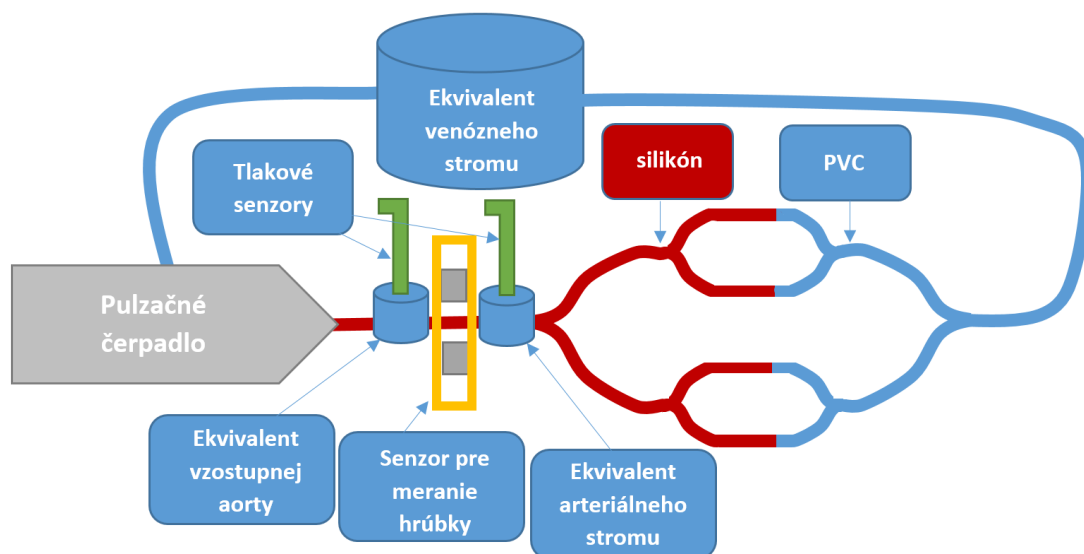
6.1 Merací reťazec

Snímanie parametrov a zisk videozáznamu boli vykonávané na umelom modeli krvného riečiska. Ako ukazuje obrázok 6.1, model je zložený z viacerých častí, ktoré sú ekvivalentom k reálnemu cievnemu systému.


Umelé srdce predstavuje pulzačné čerpadlo plniace funkciu krvnej pumpy. V tomto modeli je čerpadlo nastavené tak, aby emulovalo funkciu ekvivalentnú toku krvi u veľkých živočíchov. Technicky je to pumpa tvorená komorou s piestom a spätnými klapkami pre dodržanie jednosmerného toku krvi. Princíp prietoku kvapaliny je vo vytvorení podtlaku (posunutie piesta dovnútra), čím sa otvorí vstupná klapka a kvapalina je premiestnená do komory. Naopak, pri vytvorení pretlaku (stlačenie piesta) sa uzavrie vstupná klapka a otvorí výstupná klapka. Tým je kvapalina vytlačená do cievneho systému. Pulzačné čerpadlo ponúka možnosti zmeny srdcovej frekvencie v rozsahu 20 - 200 úderov za minútu. Srdcový výdaj je v rozmedzí 4 - 30 ml. Pre účely tejto práce boli využité frekvencie 1 Hz a 2 Hz. Srdcový výdaj bol nastavený na 10 ml a pomer systoly a diastoly bol percentuálne 35 % : 65 % [37, 38].

Ďalšou časťou modelu sú cievy. Základom je fyzický model umelej aorty (obrázok 6.2) vytvorený podľa snímku reálnej aorty z magnetickej rezonancie. Cievna časť bola podľa predlohy vytlačená do 3D modelu. Zloženie predstavuje silikón a PVC ako ukazuje obrázok 6.1 [37].

Poslednou hlavnou súčasťou umelého cievneho systému je rezervoár kvapaliny, ktorý je ekvivalentom venózneho stromu a simuluje vlastnosti žilového systému. Zapojenie je realizované podľa



Obr. 6.1: Merací reťazec modelu umelého cievneho systému vrátane externých senzorov. Prevzaté a upravené z: [37]



Obr. 6.2: Fyzický model umelej aorty (vľavo) a ukážka experimentálneho merania videozáznamu (vpravo). Zdroj: vlastné.

dizertačnej práce [37]. Kvapalina použitá pre účely hodnotenia dynamiky mechanických vlastností ciev bola roztok vody a glycerínu v pomere 3 (voda): 2 (glycerín). Meranie dopĺňujú externé senzory na meranie tlaku a hrúbky ciev vo vyznačenom segmente podľa obrázka 6.1.

6.1.1 Tlakový senzor

Umelý cievny systém popísaný vyššie disponuje konektormi Luer-Lock v miestach, kde sa spájajú hadičky. Konektory sú rozšírené v klinickej praxi pre pripájanie zdravotníckych prostriedkov. V tomto experimente sú na dané konektory pripojené tlakové senzory ARGON DTX Plus™, ktoré umožňujú meranie tlaku v rozsahu -30 mmHg až 300 mmHg s rozlíšením $5 \mu\text{V}/\text{mmHg}$ [39]. Na výstupe senzoru je napätie v jednotkách až desiatkach mV zodpovedajúce zmene tlaku. Kalibrácia senzorov bola vykonaná podľa diplomovej práce [38]. Z výsledkov kalibrácie bolo možné odvodiť lineárnu závislosť tlaku a výstupného napätia, a vyvodiť tak nasledujúci matematický vzťah:

$$P[\text{mmHg}] = 0,7356 \cdot U[\text{mV}] - 533,2800. \quad (6.1)$$




Obr. 6.3: Tlakový senzor ARGON DTX Plus™. Zdroj: [38]

6.1.2 Viacúčelový CCD laserový mikrometer: IG-028


Pre meranie hrúbky segmentu aorty bol používaný laserový senzor IG-028. Senzor je zložený z dvoch základných častí: prijímač a vysielač. Vysielač vyšle laserové svetlo s vlnovou dĺžkou 660 nm cez objekt na prijímač (CCD - lineárne pole prijímajúce svetlo). Objekt umiestnený medzi vysielačom a prijímačom vytvorí tieň na prijímači, čím je detegovaná plocha, kde nedopadá svetlo. Ako ukazuje obrázok 6.4, vďaka zmene intenzity osvetlenia dopadajúceho na maticu CCD senzor presne určí hrany objektu a tým aj jeho hrúbku [40].

Senzor umožňuje zvoliť vhodný režim merania podľa konkrétnej aplikácie. V tomto experimente je použitá možnosť merania vonkajšieho priemeru segmentu cievy. Podľa dokumentácie je montážna vzdialenosť až do 1500 mm . Je veľmi dôležitá pre presnosť merania spolu s polohou vloženého objektu. Keď je montážna vzdialenosť dlhá a objekt je ďaleko od prijímača, difrakcia svetla sa zvyšuje. Výsledok sa prejaví na snímacom čípe ako ukazuje obrázok 6.5. Pre zvýšenie presnosti



Obr. 6.4: Optický senzor IG-028 - princíp záznamu. Prevzaté a upravené z: [40]

merania bola zabezpečená čo najkratšia montážna vzdialenosť a objekt (cieva) bol posunutý bližšie k prijímaču.



Obr. 6.5: Optický senzor IG-028 - vplyv vzdialenosti medzi prijímačom a vysielačom. Prevzaté a upravené z: [40]

Senzor IG-028 umožňuje rozsah merania do 28 mm, čo je dostačujúce pre meranie hrúbky segmentu aorty. Viac informácií o senzore je dostupných v technickej dokumentácii [40].

6.2 Charakteristika dát

V rámci práce boli použité 2 sady videozáznamov. Technické parametre týchto záznamov zahŕňa tabuľka 6.1. Každé meranie obsahovalo 3 druhy dát:

- Videozáznam - dáta pre vyhodnotenie príznakov z obrazu
- Tlaková krivka - signál pre porovnanie s mechanickými vlastnosťami aorty
- Hrúbka aorty - signál pre overenie algoritmov extrakcie hrúbky z obrazu

Tabuľka 6.1: Tabuľka parametrov videozáznamu. Zdroj: vlastné.


Názov	Popis/ hodnota
Kamera	Canon EOS 550d
Objektív	Canon EF-S 18-55mm f/4-5.6 IS STM
Typ snímača	CMOS
Rozlíšenie [Mpix]	18
Rozlíšenie videa [pix]	1080 x 1920
Snímkovacia frekvencia	25
Formát videa	MOV

Počas celého procesu spracovania videozáznamu (vrátane načítania a segmentácie) je použité vysoké rozlíšenie videa (1920 px * 1080 px).

6.2.1 Videozáznamy rôznych segmentov umelej aorty

Prvá sada dát obsahuje 7 videí z rôznych segmentov aorty. Priemerná dĺžka videí je 1 minúta, čo zodpovedá 1500 snímkam. Úseky cievy na týchto videách sú tvarovo veľmi variabilné, čo je dobrým základom pre testovanie vhodného postupu segmentácie obrazu a následnej extrakcie príznakov.

Videá zahŕňajú segmenty zo vzostupnej aorty (videá 4, 5), aortálneho oblúku (video 4) aj zostupnej aorty (videá 1, 3, 6, 7). V časti zostupnej aorty taktiež jej rozvetvenie ciev (videá 2, 7). Na nasledujúcom obrázku sú snímky týchto častí vyextrahované priamo z videa. 6.6.




Obr. 6.6: Sada dát 1 - ukážky snímok rôznych segmentov aorty. Zdroj: vlastné.

6.2.2 Videozáznamy, tlak a hrúbka segmentu umelej aorty

Druhá sada dát predstavuje súbor súbežne nasnímaných videozáznamov, signálov tlaku v cieve a hrúbky cievy. Merania boli vykonané na zostupnej časti aorty, ktorá bola fixovaná v plastovom fixátore. Obrázok 6.7 predstavuje detail časti z dolného obrázka pre porovnanie a ukážku polohy externých senzorov. Zároveň je tento obrázok aj ukážkou konkrétnej snímky z videa.

Vyznačená zelená časť je oblasťou záujmu. Na tomto úseku bola meraná optickým senzorom hrúbka a dynamické zmeny vo videu. Video ohraničené obdĺžnikom bolo následne použité aj na segmentáciu a extrakciu príznakov. Druhá sada dát bola potrebná hlavne na overenie výpočtov korelácie tlakovej vlny s mechanickými vlastnosťami aorty. V dolnej časti obrázka sú označené dva tlakové senzory (Argon DTX Plus), ktoré boli umiestnené po oboch stranách tohto segmentu.



Obr. 6.7: Rozloženie senzorov merania 2. sady dát. Zdroj: vlastné.


6.2.3 Načítanie videosekvencie

Zaznamenané videá vo formáte *MOV* boli načítané do prostredia Matlab ako tri 3D matice. Prvé dve dimenzie každej matice tvoria riadky a stĺpce konkrétnej farebnej zložky a tretia dimenzia predstavuje počet snímok. Vstupom pre vlastnú funkciu je názov videa vo formáte textového reťazca a voľba počtu načítaných snímok videa.

Základom je načítanie súboru do objektu, ktorý bude obsahovať všetky potrebné dáta o videu. Vzniknutý objekt disponuje okrem samotných dát aj informáciami o videu, ako je dĺžka videa, rozlíšenie atď. Následne pomocou funkcií objektu je možné prístup k dátam a vybrať určitý počet

snímok. V cykle sú takto postupne načítané len požadované snímky videa. Výstupom sú tri 3D matice, pre červenú, zelenú a modrú zložku obrazu.

Vďaka dobrému odlíšeniu umelej cievy (červená farba) a pozadia (prevažne biela) bolo vhodné použiť modrú farebnú zložku obrazu. Keďže je cieva sýtočervenej farby, modrá zložka sa prejavuje v hodnotách blízkyh nule v regióne cievy. Pozadie tvorené bielou predstavuje naopak vysoké hodnoty každej farebnej zložky. Z toho vyplýva, že najostrejšie prechody jasovej hodnoty (hrany cievy) sú v modrej zložke. Úvahu vizuálne potvrdzuje aj obrázok 6.8.



Obr. 6.8: Porovnanie RGB zložiek obrazu - snímka z videa č. 7. Zdroj: vlastné.

Kapitola 7

Segmentačné algoritmy

Jednou z prvých oblastí praktickej časti práce je segmentácia obrazu. Tvorí základ pre analýzu obrazu a následné hodnotenie príznakov z dynamického záznamu cievneho systému. Prvá časť tejto kapitoly je venovaná stručnému rozdeleniu algoritmov pre segmentačný model aorty. Vybrané algoritmy sú bližšie rozvedené v ďalších častiach.

Segmentáciu je možné definovať ako delenie obrazu do oblastí, ktoré zodpovedajú konkrétnym objektom v obraze. Pri zachytení reálnej scény je každému pixelu v obraze priradený určitý index daného segmentu. Ak je cieľová oblasť len jedna, obraz nadobúda binárne hodnoty. V prípade binárneho obrazu je vyjadrený jeden index pre objekt a druhý pre pozadie [41].

Podľa prístupu k segmentačným algoritmom je ich klasifikácia nasledovná [41]:

1. Metódy detekcie hrán v obraze - detekcia lokálnych hrán v obraze pomocou hranových detektorov v závislosti na rozdieloch hodnôt pixelov okolia.
2. Regiónovo orientované segmentácie - založené na hodnotení homogenity obrazu
3. Štatistické metódy - základom segmentácie je štatistická analýza obrazu
4. Hybridné metódy - kombinácia viacerých techník
5. Znalostné metódy - metódy využívajúce vopred získané znalosti o objekte (modely, šablóny) a ich zhoda s obrazom.

Ďalej budú priblížené metódy, ktoré sú využité v praktickej časti práce. Preskúvané boli metódy prahovania a metóda narastania oblastí. Voľba vhodnej segmentačnej metódy vzhľadom na vstupné dáta je objektívne posúdená z hľadiska rôznych parametrov v rámci komparatívnej analýzy daných metód.

7.1 Prahovanie s využitím Otsu metódy

Otsu prahovanie predstavuje jeden z mnohých binarizačných algoritmov. Segmentácia predpokladá 2 základné triedy, do ktorých sa klasifikuje obsah obrazu: popredie (objekt) a pozadie. Ďalším predpokladom je bimodálny charakter histogramu. Súčasťou metódy je nájdenie optimálneho prahu, ktorý určí príslušnosť pixelov ku objektu alebo pozadiu. Optimálny prah, ktorý oddeľuje tieto 2 triedy predstavuje minimalizovanú hodnotu rozptylu vo vnútri týchto tried. Matematicky je rozptyl vo vnútri tried definovaný nasledovne [42, 43]:

$$\sigma_w^2(t) = \omega_{objekt}(t)\sigma_{objekt}^2(t) + \omega_{pozadie}(t)\sigma_{pozadie}^2(t). \quad (7.1)$$

Váhy objektu ω_{objekt} a pozadia $\omega_{pozadie}$ sú vyjadrené podielom pixelov danej triedy a celkovým počtom pixelov podľa prahu t . σ_{objekt}^2 je rozptyl v triede objekt a $\sigma_{pozadie}^2$ je rozptyl v triede pozadie.

Alternatívou k minimalizácii rozptylu vo vnútri triedy je maximalizácia rozptylu medzi triedami. Postup algoritmu predstavuje iteratívne prechádzanie cez každú potenciálnu prahovú hodnotu t , pričom v každej iterácii je vykonaný výpočet podľa matematického vzťahu [43, 44]:

$$\sigma_b^2(t) = \omega_{objekt}(t)\omega_{pozadie}(t) [\mu_{objekt}(t) - \mu_{pozadie}(t)]^2, \quad (7.2)$$

kde μ sú stredné hodnoty intezity tried objekt a pozadie. ω sú váhy pre objekt a pozadie.

1. Rozdelenie pixelov podľa prahu na 2 zhľuky
2. Výpočet priemeru každého zhľuku
3. Umocnenie rozdielu priemerov týchto dvoch tried
4. Vynásobenie rozdielu a počtu pixelov v oboch triedach

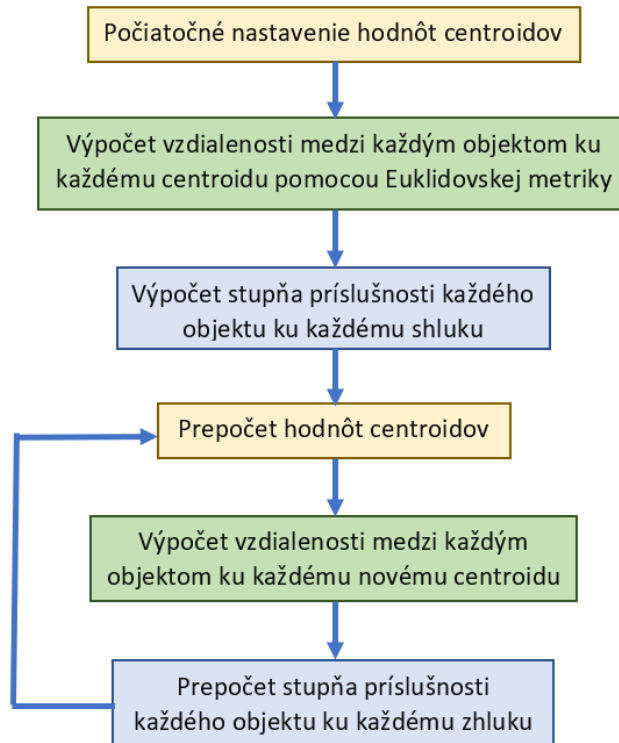
7.2 Fuzzy mäkké prahovanie

Metóda využíva tzv. mäkké zhľukovanie - algoritmus fuzzy c-means. Pri klasickom “tvrdom” prahovaní každý objekt zo súboru patrí len k jednému zhľuku. Miera, akou prislúcha objekt k zhľuku je buď 1 (patrí) alebo 0 (nepatrí). No v prípade fuzzy algoritmov každý z objektov patrí do všetkých zhľukov s určitým stupňom príslušnosti v intervale $[0, 1]$. Zároveň platí, že súčet jednotlivých stupňov príslušnosti k daným zhľukom je rovný 1 [45].

Fuzzy segmentačná metóda je zložená z 2 väčších celkov podľa publikácie [46]. Prvým je klasifikácia pixelov do jednotlivých tried - v prípade binárneho obrazu sa jedná o 2 zhľuky. Pre túto časť je využitý algoritmus fuzzy c-means. Výstupom tejto časti sú hodnoty ťažísk, ktoré sú využité pre určenie fuzzy funkcií príslušnosti. Po definovaní fuzzy príslušností je použitá lokálna agregácia.

7.2.1 Algoritmus fuzzy c-means

Prvý krokom v segmentácii je nájdenie centroidov na základe metódy c-means. Tá pozostáva z nasledujúcich krokov:



Obr. 7.1: Algoritmus fuzzy c-means. Prevzaté a upravené z: [45]


7.2.2 Fuzzy funkcie príslušnosti

Fuzzy funkcia príslušnosti predstavuje grafické vyjadrenie miery príslušnosti prvkov k určitej množine. Matematický vzťah funkcie príslušnosti $A(x)$ je zobrazením množiny U do intervalu $[0, 1]$ [45]:

$$A(x) : U \rightarrow \langle 0, 1 \rangle \quad \forall x \in U, \quad (7.3)$$

kde každému prvku x patriacemu do množiny U priradí práve jedno reálne číslo z intervalu 0 až 1 - stupeň príslušnosti.

Tieto funkcie môžu mať rôzne tvary, napríklad trojuholníková funkcia, lichobežníková funkcia, sigmoidálna funkcia alebo gaussovská funkcia. V tejto práci je použitá vzhľadom na aplikáciu lichobežníková funkcia, ktorej tvar je zobrazený na obrázku 7.2 a matematické vyjadrenie ukazujú rovnice 7.4 [45].



Obr. 7.2: Lichobežníková funkcia príslušnosti. Prevzaté z: [47]

$$\mu(x) = f(x, a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & x \geq d \end{cases} \quad (7.4)$$

7.2.3 Priestorová agregácia

Krok priestorovej agregácie využíva výhody mäkkej klasifikácie a priestorových vzťahov. Výstupom z klasifikácie sú stupne príslušnosti, ktoré sa upravujú lokálnymi informáciami podľa určitej agregáčnej schémy. Metódy agregácie zohľadnia vzťah medzi susednými pixelmi rôznymi spôsobmi [46]:

Priemerová agregácia

Agregačná funkcia vykonáva priemerovanie každej členskej funkcie podľa matematického vzťahu 7.5 s váhami ω_i . Na obrázku 7.3 je znázornený výsledok priemerovej agregácie. Vyznačený pixel v pravej časti obrázka je výsledok priemerovania jeho okolia v pôvodnom obraze.


$$\mu_l^2(l(r)) = \sum_{r_i \in \eta(r)} \omega_i * \mu_l(l(r_i)). \quad (7.5)$$

Mediánová agregácia

Agregačná funkcia vykonáva medián každej členskej funkcie podľa matematického vzťahu 7.6. Medián je definovaný ako prostredná hodnota vzostupne zoradeného vektoru.

$$\mu_l^2(l(r)) = \text{median}_{s \in \eta(r)} \{\mu(l(s))\}, \quad (7.6)$$

Schematické znázornenie týchto priestorových agregácií ukazuje obrázok 7.3:



Obr. 7.3: Ukážka výpočtu priestorovej agregácie: mediánová a priemerová. Zdroj: vlastné.


7.3 Metóda narastania oblastí

Metódu narastania oblastí charakterizujú 4 kroky. Prvým je voľba začiatočného (štartovacieho) bodu, od ktorého bude oblasť narastať. Tieto iniciačné body sa taktiež nazývajú aj semenka a ich voľbou je segmentácia značne ovplyvnená. Nastavujú sa náhodne, manuálne alebo automaticky, čomu predchádza určitá analýza obrazu. [48].

Druhým krokom je kontrola okolia týchto reprezentatívnych pixelov s ohľadom na vybrané kritérium. Podľa podmienky je ďalej rozhodnuté či pixel v okolí bude/nebude pridaný k narastajúcemu segmentu. Spôsobov kontroly okolia je viacero. Nasledujúci obrázok 7.4 ukazuje najčastejšie porovnávanie pixelov okolia voči reprezentatívnejmu pixelu (na obrázku pixel vyplnený čiernou) [48].

V algoritme bolo zvolené statické kritérium pre pridávanie pixelov k narastajúcemu segmentu. Podmienkou priradenia pixelu do objektu je rozdiel jasovej hodnoty referenčného pixelu p_{ref} voči práve prehľadávanému pixelu p_a menší ako prah T podľa vzťahu [48]:

$$|p_{ref} - p_a| < T. \quad (7.7)$$



Obr. 7.4: Spôsoby kontroly okolia u segmentácie narastania oblastí: a) vertikálne a horizontálne 4-okolie, b) diagonálne 4-okolie, c) 8-okolie. Prevzaté z: [48].

Základný matematický vzťah bol rozšírený na všetky 3 farebné zložky obrazu (p_R, p_G, p_B) . Podmienkou pre priradenie pixelu do objektu bol súčet euklidovských vzdialeností medzi referenčnými q a aktuálnymi pixelmi p nižší ako prah T :

$$d(p, q) = \sqrt{(p_R - q_R)^2 + (p_G - q_G)^2 + (p_B - q_B)^2} < T. \quad (7.8)$$

Hranica T je vypočítaná s využitím Otsu prahovania a vynásobená priemernou hodnotou modrej zložky obrázka. Pixel vyhovujúci kritériu je priradený k segmentu nastavením hodnoty 255, a taktiež je zaradený do “fronty” aby v ďalších cykloch boli takisto otestované jeho okolité pixely.

Algoritmus končí, keď je fronta prázdna, čo znamená, že žiadne pixely v okolí testovaných pixelov nevyhovujú zadanému kritériu. Tento stav môže znamenať, že algoritmus narazil na hranu obrazu alebo na posledné pixely patriace k objektu.


7.4 Morfologické operácie

Morfologické operácie sa uplatňujú v oblastiach segmentácie a zvýrazňovania obrazov. V prípade binárnych obrazov sa používajú množinové operácie typu prienik, zjednotenie, doplnok, rozdiel, transpozícia a inklúzia. Množinové operácie tvoria základ morfologických operátorov, ktoré sú zaradované do skupiny lokálnych operátorov. Je tam určitá analógia ku lokálnym konvolučným operátorom, ktoré využívajú masku pohybujúcu sa po obraze. V prípade morfologickej operácie to nie je maska ale štruktúrny element, ktorý má referenčný bod a pod jeho pozíciou sa do výstupného obrazu uloží výsledok morfologickej operácie [48].

Štruktúrny element je matica núl a jednotiek (aktívne prvky). Môže mať rôzne geometrické tvary (príkladom je obrázok 7.5 (b)), no najčastejšie sa využívajú štvorec, obdĺžnik, línia, kruh alebo elipsa. V rámci tejto práce bol využívaný štruktúrny element kruh. S ohľadom na konkrétnu aplikáciu bola veľkosť nastavená na 30 pixelov s centrálnym prvkom v strede elementu [48].

Základnými morfologickými operáciami sú erózia a dilatácia. Princípom u oboch je pohyb po obraze pixel po pixely. Kontrola erózie môže byť vyjadrená podmienkou: Ak sa pod všetkými aktívnymi

prvkami SE nachádzajú jednotky, na pozíciu referenčného bodu vo výstupnom obraze je umiestnená jednotka. V opačnom prípade ostáva výsledný pixel nezmenený. Túto situáciu zobrazuje obrázok 7.5 spolu s vyobrazením štruktúrneho elementu. Ako je viditeľné na obrázku, erózia má efekt odstraňovania, zmenšovania a rozpojovania objektov [48].



Obr. 7.5: Ukážka binárnej erózie s vyznačením aktívnych prvkov (čierne bodky). Zľava a) vstupný obraz b) štruktúrny element c) výstupný obraz po erózii. Prevzaté z: [48].

Matematicky je erózia binárneho obrazu definovaná ako prienik posunutých obrazov vstupného obrazu X . Tento súbor obrazov je vytvorený využitím vektora h , v ktorom sú uložené vektory posunu medzi centrálnym prvkom a všetkými aktívnymi prvkami SE. Pre každý vektor posunu existuje jedna verzia vstupného obrazu, ktorá je posunutá opačným smerom ako ukazuje prvok h [48]:


$$Y = \mathbf{E}_H(X) = \bigcap_{h \in H} X_{-h} \quad (7.9)$$

Operátor binárnej dilatácie je definovaný podmienkou: Ak existuje aspoň pod jedným z aktívnych prvkov štruktúrneho elementu jednotka, na pozíciu referenčného prvku vo výstupnom obraze Y je umiestnená jednotka. Princíp tejto operácie taktiež ukazuje obrázok 7.6. Z obrázku je možné vypočítavať, že dilatácia objekty zväčšuje a má tendenciu k vyplneniu prázdnych miest, čo vedie k prepojeniu objektov [48].

Matematický vzťah pri binárnej dilatácii je podobný vzťahu pri erózii, avšak s rozdielom, že namiesto prieniku posunutých obrazov je použitá množinová operácia zjednotenie [48]:

$$Y = \mathbf{D}_H(X) = \bigcup_{h \in H} X_{-h} \quad (7.10)$$

V tejto práci sú využité zrefazenia týchto dvoch morfológických operácií kvôli odstráneniu tzv. slepých škvŕn. Tieto artefakty v obraze sa vyskytovali kvôli nerovnomernému osvetleniu cievy. Taktiež kvôli jej lesklému povrchu pri dynamických zmenách - pulzácií dochádzalo k zmenám umiest-



Obr. 7.6: Ukážka binárnej dilatácie s vyznačením aktívnych prvkov (čierne bodky). Zľava a) vstupný obraz b) štruktúrny element c) výstupný obraz po dilatácii. Prevzaté z: [48].

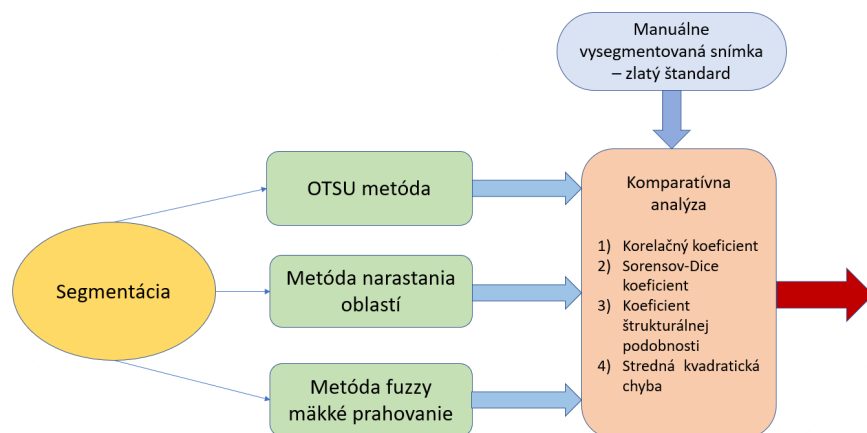
nenia a tvaru odleskov. Práve zložené morfológické operácie (otvorenie a uzavretie) sú vhodné na odstránenie malých objektov a vyhladenie tvaru objektu.

Otvorenie je postupnosť operácie erózie a dilatácie. V prípade binárneho otvorenia je podmienka zhodná s podmienkou pri erózii: Ak sú pod všetkými aktívnymi prvkami SE, ktorý je položený na obraz jednotky, do výstupného elementu sú uložené jednotky pod všetky pozície SE [48].

Uzavretie je postupnosť dilatácie a erózie. U binárneho obrazu uzavretie prebieha odlišným spôsobom ako pri doteraz spomenutých operáciách. S využitím SE nie sú filtrované objekty, ale pozadie. Ak pod všetkými aktívnymi prvkami SE, ktorý je položený na obraz, sú prvky pozadia, do výstupného obrazu je uložená nula na pozície prvkov pod SE. V opačnom prípade ostáva výstup bez zmeny [48].

7.5 Komparatívna analýza segmentačných algoritmov


Okrem subjektívneho hodnotenia odborníkmi pre konkrétnu aplikáciu segmentácie je vhodné pre porovnanie obrazu použiť objektívne parametre. Cieľom objektívneho hodnotenia kvality obrazu je navrhnúť matematické modely, ktoré by vedeli automaticky zhodnotiť a predikovať kvalitu obrazu. Jednou z možných aplikácií je komparatívna analýza pre porovnanie výsledkov algoritmov spracovania obrazu ako ukazuje schéma 7.7. Porovnávaná je snímka po segmentácii voči zlatému štandardu, ktorý predstavuje manuálne vysegmentovaný objekt. V nasledujúcej časti je priblížená manuálna segmentácia a jednotlivé parametre objektívneho hodnotenia kvality obrazu.



Obr. 7.7: Schéma komparatívnej analýzy a jej postupu. Zdroj: vlastné.

7.5.1 Manuálne vysegmentované snímky (zlatý štandard)

Pre vytvorenie zlatého štandardu (binárnych obrazov) je použitý nástroj prevzatý z [49]. Umožňuje generovať masku s jednou alebo viacerými oblasťami záujmu (ROI). Taktiež umožňuje výber tvaru oblastí: obdĺžnik, elipsa, nepravidelný mnohoúhelník alebo voľne nakreslený tvar. Pre extrakciu masky v tejto aplikácii bol použitý voľne nakreslený tvar. Jedná sa o uzavretú krivku, ktorá tvorí masku identifikovaného objektu. Maska bola následne použitá ako šablóna pre vytvorenie binárneho obrazu tak, aby nakreslená krivka vytvárala hranicu okolo objektu. Ukážka manuálnej segmentácie s ohraňením objektu je na obrázku 7.8:



Obr. 7.8: Ukážka manuálnej segmentácie. Zdroj: vlastné.

7.5.2 Pearsonov korelačný koeficient

Parameter vyjadruje mieru lineárneho vzťahu medzi dvoma premennými. Korelačný koeficient sa pohybuje v rozmedzí -1 až 1. Negatívna hodnota koeficientu znamená, že stúpajúca hodnota prvej premennej vyvolá pokles hodnoty druhej premennej. Hodnota -1 teda značí silný negatívny vzťah

medzi premennými. Naopak, pri hodnote 1 je vyhodnotenie korelácie ako úplnej pozitívnej lineárnej závislosti. Ak má stúpajúcu tendenciu jedna premenná, rovnaký tvar má aj druhá premenná. Z tohto dôvodu sa pri korelácii signálov taktiež hovorí aj o miere podobnosti tvaru signálov. V prípade, že nie je vzťah medzi premennými, sú lineárne nezávislé a ich korelačný koeficient je rovný 0 [50]. Interpretáciu korelačného koeficientu popisuje nasledujúca tabuľka [51]:

Tabuľka 7.1: Interpretácia korelačného koeficientu podľa Guilforda. Prevzaté z: [51].

Hodnota korelačného koeficientu	Interpretácia
0 - 0,2	zanedbateľný vzťah
0,2 - 0,4	nie príliš tesný vzťah
0,4 - 0,7	stredne tesný vzťah
0,7-0,9	veľmi tesný vzťah
0,9 - 1	extrémne tesný vzťah

Matematická definícia 7.11 predpokladá, že medzi veličinami X a Y je lineárna závislosť, pričom x_i a y_i sú hodnoty nezávislého výberu. Ich výberové priemery sú označované ako \bar{x} a \bar{y} .

$$r_{x,y} = \frac{\overline{x \cdot y} - \bar{x} \cdot \bar{y}}{\sqrt{x^2 - (\bar{x})^2} \cdot \sqrt{y^2 - (\bar{y})^2}}, \quad (7.11)$$

pričom výberové priemery sú počítané podľa:

$$\overline{x^2} = \frac{1}{n} \sum_{i=1}^n x_i^2, \quad \overline{y^2} = \frac{1}{n} \sum_{i=1}^n y_i^2, \quad \overline{x \cdot y} = \frac{1}{n} \sum_{i=1}^n x_i \cdot y_i. \quad (7.12)$$

7.5.3 Index štruktúrálnej podobnosti (SSIM)

Základnou myšlienkou tohto parametru je, že pixely v pôvodnom obrázku obsahujú užitočné informácie o štruktúre scény. Vďaka meraniu týchto štruktúrálnych informácií je užívateľovi poskytnutá dobrá aproximácia skreslenia obrazu. Tento algoritmus definuje degradáciu obrazu ako štruktúrlnu zmenu. Podobnosť je zisťovaná v 3 oblastiach [52]:

- Porovnanie podľa jasů
- Porovanie podľa kontrastu
- Porovnanie podľa štruktúr obrazu

Matematicky je možné tento index vyjadriť podľa [53]:

$$SSIM = \frac{(2\bar{y}\bar{x} + c_1)(2\sigma_{xy} + c_2)}{(\bar{y}^2 + \bar{x}^2 + c_1)(\sigma_y^2 + \sigma_x^2 + c_2)}, \quad (7.13)$$

s vyjadrením vnútorných vzťahov:

$$\begin{aligned}\bar{x} &= \frac{1}{L} \sum_{i=1}^L x_i, & \bar{y} &= \frac{1}{L} \sum_{i=1}^L y_i \\ \sigma_x^2 &= \frac{1}{L-1} \sum_{i=1}^L (x_i - \bar{x})^2, & \sigma_y^2 &= \frac{1}{L-1} \sum_{i=1}^L (y_i - \bar{y})^2 \\ \sigma_{xy} &= \frac{1}{L-1} \sum_{i=1}^L (x_i - \bar{x}) \cdot (y_i - \bar{y}).\end{aligned}\tag{7.14}$$

Kde premenná x je pôvodný obraz, y je testovaný obraz po segmentácii a L je počet pixelov v časti, kde je obraz spracovávaný. $c1$, $c2$ predstavujú stabilizačné konštanty pre prípad slabého menovateľa. σ_x , σ_y sú rozptyly zo vzoriek signálu x a y a vzájomné väzby medzi x a y vyjadruje σ_{xy} . Hodnota tohto indexu sa pohybuje v rozmedzí $[-1, 1]$, kde hodnota 1 znamená úplnú rovnosť $x = y$ [53, 54].

7.5.4 Sorensov-Dice koeficient (SDC)

Tento parameter má v literatúre viacero tvarov, no vo väčšine prípadov je pomenovaný po svojich 2 objaviteľoch Sorenson (z roku 1948) a Dice (z roku 1945), ktorí tento štatistický parameter objavili nezávisle. Podľa publikácie [55] je definovaný pre 2 konečné množiny:

$$SDC(A, B) = \frac{2|A \cap B|}{|A| + |B|},\tag{7.15}$$

kde $|A|$ a $|B|$ reprezentujú kardinality týchto dvoch množín (počet prvkov). Podľa výrazu je zrejmé, že sa koeficient rovná dvojnásobku počtu prvkov spoločných pre obe množiny A, B. Následne je súčin podelený súčtom prvkov v každej množine. Výsledná hodnota leží v intervale 0 až 1. Čím je hodnota vyššia, tým je vyššia aj podobnosť množín.

7.5.5 Stredná kvadratická chyba (MSE)


MSE taktiež patrí medzi veľmi používané metriky merania kvality obrazu. Oproti predošlým parametrom je interpretácia tohto parametru odlišná. Čím je hodnota MSE nižšia, tým je vyššia kvalita obrazu. Stredná kvadratická chyba je vyjadrená medzi dvomi obrázkami ako [56]:

$$MSE = \frac{1}{MN} \sum_{n=0}^M \sum_{m=1}^N [\hat{g}(n, m) - g(n, m)]^2,\tag{7.16}$$

kde \hat{g} a g sú 2 porovnávané obrázky s veľkosťou okna $M \times N$.

7.6 Návrh a implementácia výsledného segmentačného algoritmu

Po zhodnotení výsledkov komparatívnej analýzy 3 druhov segmentácií bol vytvorený algoritmus s využitím metódy Otsu prahovania (v časti 11.2 je odôvodnený jeho výber). Konkrétny návrh krokov algoritmu ilustruje nasledujúci obrázok 7.9.



Obr. 7.9: Ukážka výsledného segmentačného algoritmu a jeho postup. Zdroj: vlastné.

Algoritmus používa multiregionálne prahovanie Otsu vysvetlené v podkapitole 7.1. Bolo vytvorených 10 úrovní prahu, z ktorých je použitá 3. prahová hodnota zistená experimentálne. Ďalším krokom je binarizácia obrazu podľa prahovej hodnoty, kedy segmentácia predpokladá 2 základné triedy (objekt reprezentovaný indexom 0 a pozadie reprezentované indexom 1). Hodnoty indexov majú na začiatku opačný význam v porovnaní so zvyčajným značením binárnych obrazov. Dôvodom je, že pre spracovanie nie je použitý šedotónový obraz, ale modrá farebná zložka obrazu. Za predpokladu, že dominantná farebná zložka cievy je červená a pozadie cievy je biele, objekt nadobúda po binarizácii hodnotu nula.

Následne je vytvorený komplement obrazu, na ktorý je aplikovaný algoritmus zaplnenia menších dier. Ak aj po tejto morfolologickej rekonštrukcii v obraze stále ostávajú nezaplnené miesta, je použitá morfológická operácia otvorenie do veľkosti mediánu zistených štruktúr v obraze. Takto vyplnený obraz obsahuje väčšinou už len okrajové chyby a na vyhladenie okrajov je použitá mediánová filtrácia a morfológická operácia uzavretie.

Základom mediánovej filtrácie je usporiadanie susedných bodov obrazu podľa veľkosti jasovej hodnoty. Pixely sa nachádzajú v tzv. maske o rozmere 30 pixelov. Do strednej pozície tejto masky je vždy vybratý medián týchto pixelov. Funkciu masky pri morfolologickej operácii uzavretie predstavuje štruktúrny element kruh s veľkosťou 30 pixelov (bližšie popísaný v podkapitole 7.4).

Kapitola 8

Implementácia a extrakcia príznakov z videosekvencie

Binárne obrazy boli vstupnou informáciou ku extrakcii príznakov, ktoré kvantifikujú objekt v obraze – v tomto prípade aortu v konkrétnom čase. V rámci práce bol naprogramovaný algoritmus na počítanie týchto príznakov v časovej rade pre každú snímku videa. Týmto spôsobom bolo vykonané následné hodnotenie geometrie.

Z obrazu boli počítané príznaky: plocha, obvod, vlnitosť a hrúbka. Taktiež bolo odskúšané, akú výpovednú hodnotu budú mať parametre odvodené od hrúbky - stredná hodnota a rozptyl distribúcie hrúbky v čase. V tejto kapitole bude taktiež priblížený princíp skeletonizácie a distančnej mapy, ktoré sú použité na medzivýpočty vlnitosti a distribúcie hrúbky.

8.1 Plocha a obvod aorty

Plocha objektu je vypočítaná ako súčet pixelov objektu. Obvod je získaný ako súčet euklidovských vzdialeností dvojíc susedných pixelov na hranici objektu. Pri týchto parametroch sa ukazuje dôležitosť presnej segmentácie, pretože ak obrázok obsahuje nesúvislé oblasti, prípadne nejaké izolované pixely, výsledky sú zafaržené chybou. Výsledky priebehu týchto extrahovaných príznakov sú zobrazené a vyhodnotené v podkapitole 11.3.

8.2 Vlnitosť a distribúcia hrúbky aorty

Skeletonizácia a distančná mapa

Skelet objektu predstavuje jednu z často používaných morfologických transformácií binárneho obrazu. V tomto použití je významná hlavne kvôli tomu, že poskytuje tvarovú klasifikáciu objektu s využitím detekcie koncových bodov. Skelet predstavuje líniu definujúcu stred objektu a tým umožňuje


získať informáciu o tvare objektu, výskytu dier, rôznych vetvení a výbežkov. Algoritmov pre detekciu kostry v obraze je mnoho. V rámci tejto práce bola skeletonizácia spojená s distančnou mapou [48].

Pomocou vzdialenostných metrík je možné v diskretnom obraze kvantitatívne určiť vzdialenosti medzi pixelmi. Medzi často používané patria manhattanská vzdialenosť d_M a euklidovská vzdialenosť d_E . Obrázok 8.1 ukazuje geometrickú interpretáciu týchto dvoch metrík medzi bodmi A, B. V prípade manhattanskej vzdialenosti (červená a zelená čiara) existuje viac ako jedna možnosť, ale spojenie vždy vedie po pravouhlej sieti s podmienkou najkratšej vzdialenosti [48]:

$$d_M(A, B) = \sum_{i=1}^n |(A_i - B_i)|. \quad (8.1)$$

Euklidovská vzdialenosť (modrá čiara) je matematicky vyjadrená ako:

$$d_E(A, B) = \sqrt{\sum_{i=1}^n (A_i - B_i)^2}. \quad (8.2)$$



Obr. 8.1: Vzdialenostné metriky: manhattanská a euklidovská vzdialenosť. Prevzaté a upravené z: [48].

Na základe vzdialeností pixelov v obraze je vytvorená distančná mapa binárneho obrazu. Pracuje na princípe podľa matematického vzťahu 8.3 tak, že priradí hodnotu každému pixelu v rámci objektu (v prípade binárneho obrazu tam kde sú jednotky) zhodnú so vzdialenosťou medzi týmto pixelom a najbližším bodom pozadia (prvá nula za hranicou objektu) [48].

$$D(x)|_{i,k} = \min_{m,n} [d((i, k), (m, n)), x_{m,n} = 0]. \quad (8.3)$$

Podľa definície je pixelu (i, k) distančnej mapy $D(x)$ obrazu x priradená vzdialenosť d medzi pixelom (i, k) a pixelom (m, n) . Bod (m, n) predstavuje najbližší bod binárneho obrazu s hodnotou 0 [48].

Vzhľadom na konkrétnu aplikáciu a vďaka presnejším výpočtom je pre algoritmus distribúcie hrúbky využitá Euklidovská vzdialenosť.

8.2.1 Výpočet vlnitosti

Výpočet vlnitosti bol v tejto práci určitým experimentálnym parametrom vyjadrujúcim mieru globálneho zakrivenia objektu. Publikácie, ktoré zahŕňajú výpočet vlnitosti z obrazu sú väčšinou sústredené priamo na vlnitosť kolagénových vlákien v cieve [57]. Podľa citovanej publikácie sú zaznamenávané zmeny pri vzrastajúcom tlaku v tepne. V kontexte tejto práce bola hľadaná periodicitá vlnitosti ako dôsledok dynamických zmien aorty, ktoré sú tiež periodické. Parameter vlnitosti je definovaný ako [57]:

$$w = \frac{L_f}{L_o}, \quad (8.4)$$

kde w je vlnitosť vypočítaná ako podiel L_f priamej vzdialenosti a L_o dĺžky cievy.

Priama vzdialenosť je získaná výpočtom kostry objektu a následnou detekciou počiatočného a koncového bodu ako je znázornené na obrázku 8.2.

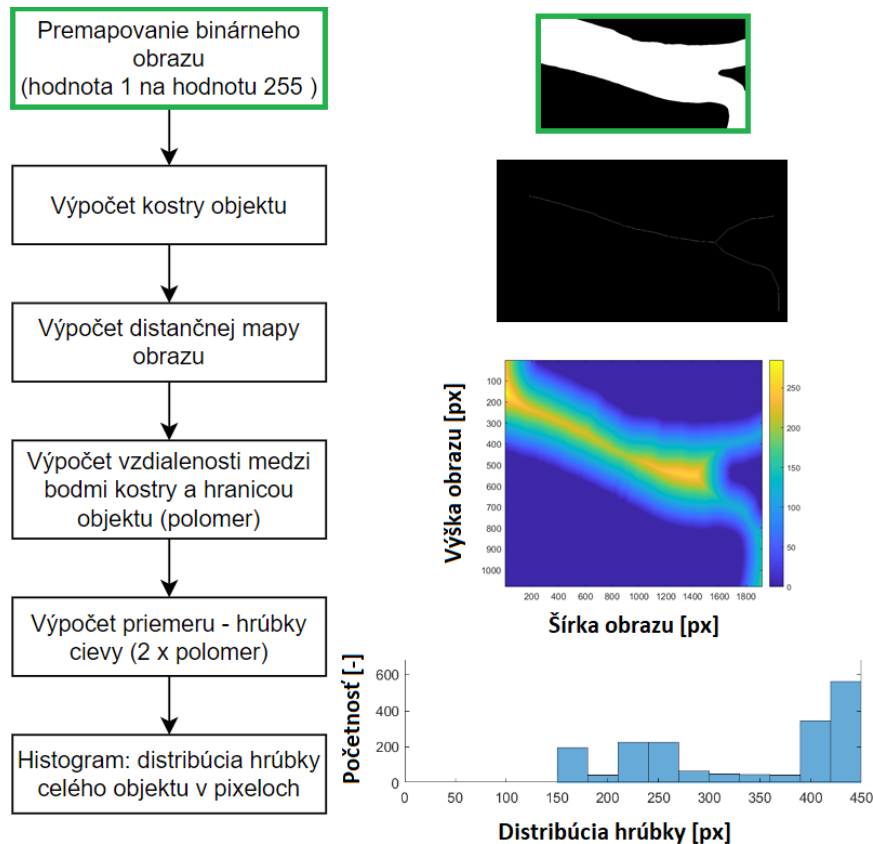


Obr. 8.2: Výpočet kostry obrazu a následná detekcia počiatočných (resp. koncových) bodov v porovnaní so vstupným binárnym obrazom. Zdroj: vlastné.

Algoritmus taktiež ošetruje prípad, ak by kostra obrazu mala nesúvislé časti menšie ako 100 pixelov. To zvyčajne nastávalo pri videách, ktoré zachytávali cievu v oblasti jej rozvetvenia. V prípade detekcie viac ako 2 koncových bodov je rozhodujúcim faktorom najväčšia dĺžka skeletu v horizontálnom smere. Medzi týmito dvomi bodmi je potom počítaná priama vzdialenosť. Dĺžka cievy je rovná súčtu pixelov kostry v danej časti.

8.2.2 Výpočet distribúcie hrúbky

Distribúcia hrúbky vysegmentovanej časti cievy využívala princíp skeletonizácie a distančnej mapy, ktorých technický základ je uvedený v podkapitole vyššie. Postup algoritmu je zobrazený na obrázku 8.3.



Obr. 8.3: Postup výpočtu distribúcie hrúbky. Zdroj: vlastné.

Vstupom je binárny obraz, ktorý po premapovaní nadobúda hodnoty 0 a 255 (na miestach, kde bola pôvodne hodnota jedna) kvôli ďalším výpočtom. Na objekt je aplikovaná skeletonizácia, ktorej výsledkom je stenčenie všetkých prvkov objektu na šírku jedného pixelu, teda na tzv. kostru objektu. V smere kolmom na rovinu kostry je zisťovaná vzdialenosť od hranice objektu. Metóda výpočtu vzdialeností vypočíta vzdialenosti od nulových pixelov k najbližším nenulovým pixelom. Vstupom distančnej mapy je negatív vstupného premapovaného obrazu. Výsledné mapovanie týchto vzdialeností taktiež znázorňuje časť obrázka 8.3, kde je pozadie vyznačené tmavomodrou farbou. Obrázok ukazuje, že na hranici aorty je vzdialenosť nulová a čím bližšie je pozícia pixelov ku kostre obrazu, tým je vzdialenosť vyššia. Najväčšia vzdialenosť je zobrazená sýto žltou farbou.

Polomer hrúbky je rovný vzdialenosti medzi bodmi kostry a hranicami objektu. Vynásobením dvomi je získaná hrúbka pre daný bod kostry. Na obrázku je ukážka možnosti vizualizácie a vý-

počtu distribúcie hrúbky zo všetkých bodov kostry histogramom. Histogram vyjadruje početnosť konkrétnych hodnôt hrúbky v danej snímke videa.

Odvožené parametre hrúbky - stredná hodnota a rozptyl

Stredná hodnota hrúbky je pre každú snímku vypočítaná ako priemerná hodnota hrúbky všetkých bodov kostry. Vyjadruje hrúbku všetkých častí cievy, nielen v mieste najväčšej dynamiky. Druhým odvođeným parametrom je rozptyl, ktorý sa taktiež počíta pre každú snímku zo všetkých hodnôt hrúbky v danej snímke.

Kapitola 9

Grafické užívateľské rozhranie

Grafické užívateľské prostredie (ďalej len GUI) slúži k demonštrovaniu funkcionality jednotlivých modulov práce. Pozostáva z 3 hlavných funkcií: načítanie videa, segmentácia aorty a extrakcia príznakov z obrazu. Viac o ich funkcionalite je v kapitolách 6, 7 a 8. Základom GUI bolo vytvorenie okna, ktoré slúži ako kontajner. Do neho boli potom programovo pridávané ďalšie komponenty (popisky, tlačidlá a zobrazovacie prvky).


9.1 Načítanie videa

Aplikácia umožňuje načítanie videa a voľbu farebnej zložky obrazu, ktorá má byť ďalej spracovávaná. Rozlíšenie videa je znížené kvôli časovej náročnosti na polovicu. Okrem voľby farby je možné nastaviť informáciu o tom, koľko snímok bude spracovávaných. Hodnota je prednastavená na 250 a môže byť zmenená posúvaním bežca. Ako už bolo v predošlých kapitolách spomenuté, v práci je použitá modrá farebná zložka obrazu z dôvodu najväčších rozdielov jasových hodnôt medzi objektom (aortou) a okolím. Po kliknutí na tlačidlo “Vybrať video“ je užívateľ presmerovaný do priečinka s videami a vykoná výber. Po načítaní videa sa v pravej časti okna zobrazí náhľad tohoto videa. Tieto kroky ukazuje obrázok 9.1.

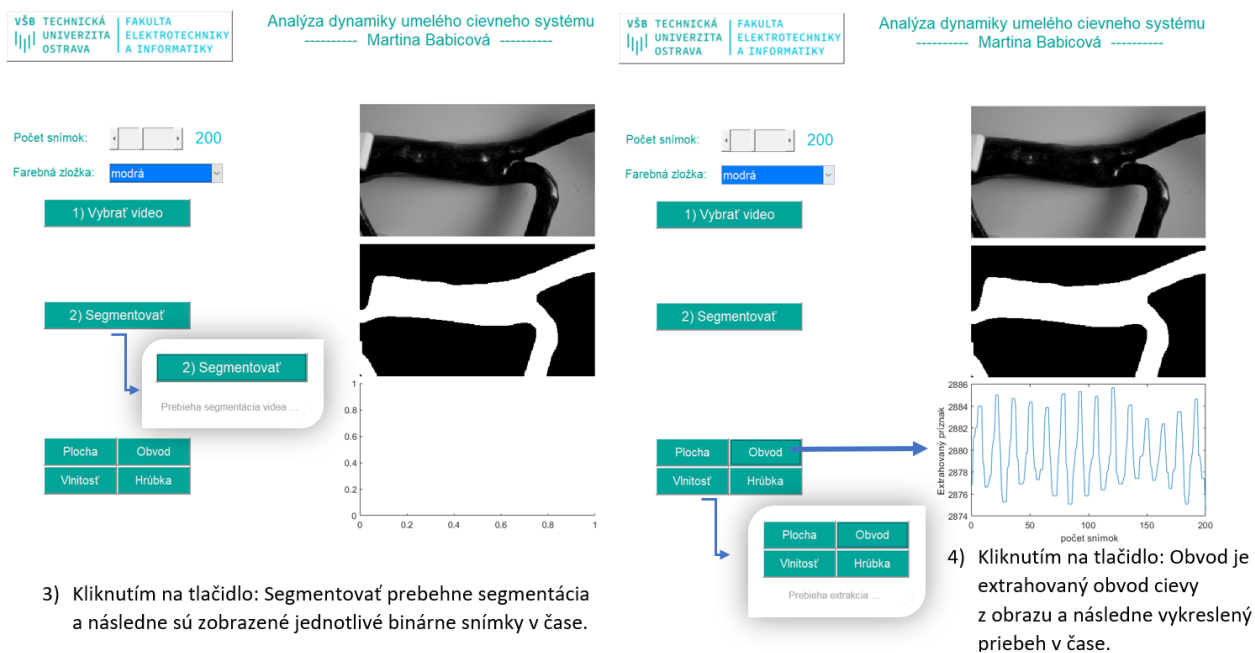
9.2 Segmentácia a extrakcia príznakov

Spustenie segmentácie vyžaduje, aby bolo video načítané. Užívateľovi je potom umožnené pomocou tlačidla “Segmentovať“ spustiť segmentovanie snímok. Výsledky segmentácie sú opäť viditeľné v pravej časti okna pod náhľadom zvoleného videa (obrázok 9.2 - ľavá časť).

Po úspešnom dokončení segmentácie sú aktivované posledné 4 tlačidlá pre extrakciu jednotlivých príznakov z obrazu: plocha, obvod, vlnitosť a hrúbka. Každý príznak je extrahovaný samostatne pomocou konkrétneho tlačidla. Vykreslenie signálu je taktiež zobrazené v grafe.



Obr. 9.1: Ukážka chodu aplikácie pre časť výber, načítanie a zobrazenie videa. Zdroj: vlastné.



Obr. 9.2: Ukážka chodu aplikácie pre časť segmentácie obrazu a extrakcie videa. Zdroj: vlastné.

Postupnosť týchto krokov je v pravej časti obrázka 9.2. V prílohe C je ukážka celkového náhľadu GUI po vykonaní jednotlivých funkcií.

Grafické užívateľské prostredie taktiež ukazuje na veľmi dobrú použiteľnosť modrej farebnej zložky obrazu v ďalšom spracovaní. Naopak použitie červenej zložky obrazu je nevhodné pre segmentáciu cievy. Dôvodom je práve farba objektu (červená cieva) a jeho odlišitosť od pozadia (biela) v červenej zložke obrazu. Viac k výberu modrej zložky je v podkapitole 6.2.3.

Kapitola 10

Algoritmus korelácie mechanických vlastností ciev s tlakovou vlnou

V rámci praktickej časti tejto práce bol realizovaný návrh a implementácia algoritmu korelácie mechanických vlastností cievy s tlakovou vlnou. Vstupnými dátami boli súčasne snímané videozáznamy konkrétneho úseku aorty, signál tlakovej krivky a hrúbka aorty. Po načítaní videa boli pre všetky snímky videosekvencie vybrané konkrétne regióny záujmu ako je uvedené v podkapitole 6.2.2.

Algoritmus je zložený z 3 hlavných celkov. Prvá časť predstavuje pedspracovanie surových dát z externých senzorov. Následne sú v druhej časti upravené extrahované príznaky z videosekvencie kvôli kolísaniu nulovej izolínie. Posledná časť obsahuje samotný výpočet korelačného koeficientu medzi príznakmi z obrazu a tlakovou vlnou.

10.1 Pedspracovanie signálov z externých senzorov


Signály získané externými senzormi mali rozdielnu vzorkovaciu frekvenciu ako rýchlosť snímok videa. Ako už bolo spomenuté vyššie, video bolo snímané s frekvenciou 25 snímok za sekundu. Tlakový senzor mal vzorkovaciu frekvenciu 200 Hz a optický senzor mal vzorkovaciu frekvenciu 100 Hz.

Predtým, než boli tieto signály porovnávané, bola vykonaná interpolácia podľa pomeru frekvencií. Je využitý princíp lineárnej interpolácie. Keďže sú známe 2 body so súradnicami x , y , tak interpolácia je priamka medzi týmito dvomi bodmi. V tomto prípade bol príznak z obrazu predĺžený na štvornásobok v prípade frekvencie 100 Hz a na osemnásobok v prípade frekvencie 200 Hz podľa pomeru 100:25, 200:25.

Druhou časťou pedspracovania signálov hrúbky a tlaku bola filtrácia. Rušenie vyskytujúce sa v signáli môže do určitej miery ovplyvniť výsledok korelácie a skresliť výsledok. Podľa charakteru šumu v signáli bola zvolená filtrácia s využitím vlnkovej transformácie. Dôvodom bola znalosť tepovej frekvencie umelého cievneho systému, a tým aj interval frekvenčného pásma užitočnej zložky signálu.

V prvom kroku bol použitý softvér podľa publikácie [58], vďaka ktorému bola vhodne zvolená vlnka a stupeň dekompozície pre rozklad vlnkovou transformáciou. Tento systém predikuje vhodný výber parametrov (typ vlnky a stupeň dekompozície) pre vyhladenie dát. Úroveň dekompozície odpovedá úrovni dilatácie vlniek. Výsledkom sú vygenerované matice odozvy pre vybrané typy vlniek a úrovni rozkladu (matica koeficientov podľa voľby). Algoritmus bol otestovaný parametrami MSE (stredná kvadratická chyba), ED (euklidovská vzdialenosť) a Corr (korelačný koeficient) [58]. Farebná škála na obrázku 10.1 ukazuje hodnotu použitého parametra.


Postup získania vhodnej vlnky a stupňa rozkladu bol rozdelený do viacerých krokov. Najskôr bola vybratá jedna rodina vlniek a hodnoty SNR (Signal To Noise Ratio). Tieto hodnoty udávajú aké množstvo šumu má byť pridané do natívneho signálu. Následne rozkladom vlnkovou transformáciou a prahovaním bola odfiltrovaná pôvodná zložka a vypočítané testovacie parametre MSE, ED a Corr. Iteratívne bol postup opakovaný pre ďalšie vlnky a stupne dekompozície s výstupom farebne mapovaných matíc, ako ukazuje obrázok 10.1 [58].



Obr. 10.1: Farebné mapovanie hodnôt korelačného koeficientu v závislosti na type vlnky a stupni dekompozície. Zdroj: vlastné.


Z výsledkov korelačných koeficientov vyplýva, že najvhodnejší stupeň dekompozície je 6 a vhodná vlnka z rodiny Daubechies je *db5*. Tieto parametre sa stali vstupom pre rozklad signálu diskretnou stacionárnou 1-D vlnkovou transformáciou. Výsledok je zobrazený na obrázku 10.2.

Po rozklade na 7 pásiem bolo prvých 5 (v prípade tlakovej krivky) a prvé 4 (v prípade hrúbky v mm) pásma nulované. Vďaka informácii o frekvencii užitočnej zložky tlakovej krivky je možné usúdiť, že frekvencie nad 3.125 Hz sú veľmi pravdepodobne šum. Z tohto dôvodu sú v konkrétnych pásmach vlnkové koeficienty nulované a týmto spôsobom odstránené z celkového signálu.



Obr. 10.2: Ukážka rozkladu vlnkovou transformáciou so 6 stupňami dekompozície a využitím vlnky db5. Zdroj: vlastné

Po spätnej vlnkovej transformácii je šumová zložka odfiltrovaná. Porovnanie signálov pred a po filtrácii zobrazuje obrázok 10.3.



Obr. 10.3: Porovnanie natívnych signálov tlaku a hrúbky (modrá) voči signálom po filtrácii (červená). Zdroj: vlastné.

10.2 Predspracovanie extrahovaných príznakov obrazu

Extrahované príznaky z obrazu prinášajú informáciu o mechanických vlastnostiach cievy. Pomocou týchto parametrov dokážeme kvantifikovať objekt v obraze - v tomto prípade aortu v konkrétnom čase. Matematicky sú reprezentované 1D signálmi. Nachádzalo sa tu aj rušenie tzv. artefaktom RBM (Rigid Body Motion). Dôvodom tejto plávajúcej zeme je vplyv mechanických vlastností tlaku, ktorý spôsobuje prúdiaca kvapalina v aorte. Užitočná zložka nie je tvarovo deformovaná. Tento artefakt sa prejaví len kvôli posunom polohy aorty.


Korekcia nulovej izolínie bola prevedená s využitím EMD (Empirical Mode Decomposition) metódy [59]. Metóda predstavuje rozklad na súčet tzv. IMF (funkcií vnútorného režimu). Bázové funkcie boli odvodené priamo zo signálu. Rekurzívne sú extrahované rôzne rozlíšenia zo samotného signálu bez použitia pevných funkcií ako napríklad vlnková analýza. Postup algoritmu je zložený z viacerých krokov:

1. Výpočet lokálnych maxím a miním vstupného signálu
2. Výpočet obálky maxím a miním pomocou kubickej interpolácie
3. Výpočet priemeru získaných obálok e (hornej z maxím a dolnej z miním)
4. Výpočet rozdielu R medzi vstupným signálom x a priemerom obálok e . Ak rozdiel splní podmienky IMF, rozdielový signál sa stane prvou IMF. Ak podmienky nie sú splnené, postup prvých troch krokov sa zopakuje, avšak vstupom je namiesto pôvodného signálu x rozdielový signál R .
5. Výpočet zvyšku signálu ako rozdiel vstupu x a R pre 2. IMF.
6. Algoritmus končí, keď je zvyškový signál R stály, monotónny alebo je v signále iba jeden extrém.

Bázové funkcie IMF musia spĺňať 2 podmienky, ktoré platia v bode 4. ukážky postupu algoritmu [59]:

- Počet extrémov je rovný počtu priechodov nulou s výnimkou prípadu, kedy je v signále už iba jeden.
- Výpočet strednej hodnoty z obálok miním a maxím je v každom bode rovný nule.

EMD metóda ako taká, nie je filtračná metóda. Je to len metóda pre rozklad signálu, no pre samotnú filtráciu bolo následne použité odstránenie poslednej nízko-frekvenčnej zložky (odčítaním zo signálu). Zložka s najnižšou frekvenciou korešponduje s kolísaním nulovej izolínie. Porovnanie pôvodného a filtrovaného signálu ukazuje obrázok 10.4.



Obr. 10.4: Porovnanie pôvodného signálu plochy pred filtráciou a po filtrácii s využitím EMD. Modrá farba je pôvodný signál, červená farba je vyfiltrovaný signál. Zdroj: vlastné

10.3 Korelácia tlakovej vlny s mechanickými vlastnosťami cievy

Mechanické vlastnosti cievy popisujú 4 extrahované parametre z obrazu. V korelačnom algoritme bola porovnávaná plocha, obvod, vlnitosť a hrúbka voči signálu tlakovej krivky. Navyše boli porovnané odvodené ďalšie parametre z hrúbky (stredná hodnota a rozptyl). Podľa vizuálneho zhodnotenia tvaru a frekvencie vypočítaných príznakov bolo možné predpokladať ich koreláciu s tlakovým namáhaním. Overovaniu tejto korelácie je verovaná ďalšia časť.

Vstupom do korelačného algoritmu sú 1D signály (plocha, obvod, vlnitosť, priemerná hrúbka a rozptyl hrúbok) a pole 1D signálov (hrúbka). Hrúbka je následne ďalej spracovávaná pre koreláciu s tlakovou krivkou, ktorá je taktiež reprezentovaná 1D signálom. Hrúbka bola vždy vypočítaná pre všetky body kostry vo všetkých snímkach. Kvôli tomu je výstupný tvar premennej vo forme bunkového poľa s veľkosťou rovnou počtu snímok. Každá bunka poľa obsahuje vektor hrúbok pre všetky body kostry. Dôležitou súčasťou hodnotenia dynamiky a priebehu tohto parametru bolo zistenie miesta (bod na kostre), kde nastávajú najväčšie zmeny počas pulzného toku kvapaliny. Na hodnotenie bola využitá smerodajná odchýlka podľa vzťahu 10.1. Smerodajná odchýlka bola vypočítaná pre každý bod kostry pre všetky snímky. Maximálna smerodajná odchýlka vyjadrovala miesto najväčšej premenlivosti hrúbky v konkrétnom bode kostry. Na tomto mieste (bod kostry) sú zaznamenané najväčšie zmeny dynamiky cievneho systému.

Smerodajná odchýlka je definovaná ako druhá odmocnina rozptylu [60], kde A je vektor príznaku pre všetky snímky, μ je priemer vektoru príznaku a N je počet prvkov vektoru A :

$$S = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2}. \quad (10.1)$$

Korelácia prebiehala v posuvnom okne, aby bola zaručená presná synchronizácia začiatku periódy oboch skúmaných signálov. Je nutné si uvedomiť, že táto korelácia z teoretického hľadiska predstavuje závislosť medzi príčinou (tlaková vlna) a následkom (pohyb cievy). Z tohto dôvodu je súčasťou algoritmu hľadanie správneho posunu signálov voči sebe. Signál tlakovej krivky bol o niečo dlhší ako príznak z obrazu. Príznak z obrazu sa s krokom 5 posúval po signále tlaku a v každom okne bol vypočítaný korelačný koeficient. Následne bola vždy uložená pozícia plávajúceho signálu, aby bolo možné určiť, v akej polohe majú signály najväčšiu koreláciu.

Výsledky tejto časti predstavujú korelačné koeficienty pre každý príznak voči 2 druhom tlakových kriviek. Keďže bol tlak meraný v časti oblúku aorty a na zostupnej časti aorty, je v kapitole 11 zhrnutie a porovnanie oboch tlakových kriviek.

Kapitola 11

Výsledky testovania navrhnutých algoritmov

Táto kapitola obsahuje výsledky jednotlivých častí diplomovej práce. Na začiatku sú výsledky komparatívnej analýzy ako podkladu k vytvoreniu finálneho segmentačného modelu. Následne sú zobrazené ukážky binárneho modelu cievy pre 7 videí. Ďalšia časť je venovaná výsledkom extrakcie príznakov a zhodnoteniu ich priebehu. Poslednou súčasťou sú výsledky korelačného algoritmu.

11.1 Výsledky segmentačných algoritmov a komparatívnej analýzy

V tejto sekcii sú postupne ukázané výsledky 3 segmentačných algoritmov. Prvý je prahovací a využíva vyhodnotenie histogramov (Otsu prahovanie). Druhý, taktiež prahovací, pri ktorom bolo použité tzv. mäkké prahovanie s fuzzy algoritmom c-means. Tretím algoritmom bola metóda narastania oblastí. Pre porovnanie použitia segmentačnej metódy s morfológickou operáciou je taktiež zahrnutá do analýzy metóda narastania oblastí s uzavretím. Komparatívna analýza algoritmov bola hodnotená pomocou 4 objektívnych parametrov:

1. Korelačný koeficient
2. Sorensov-Dice koeficient
3. Koeficient štruktúrálnej podobnosti
4. Stredná kvadratická chyba

11.1.1 Výsledky algoritmu s využitím prahovania Otsu

Prahovanie na báze hodnotenia histogramov prinieslo veľmi dobré výsledky. Najväčšou prednosťou metódy je vysoká rýchlosť pri dosiahnutí dobrých výsledkov. V obraze sa vyskytovali odlesky z dôvodu nerovnomerného osvetlenia a lesklého povrchu aorty. Väčšie odlesky algoritmus vyhodnotil nesprávne, tak ako ukazuje obrázok 11.1. Keďže priestorová informácia nebola hodnotená a binarizácia bola závislá iba od prahovej hodnoty, svetlé odlesky tvorili v obraze diery a súčasťou objektu boli regióny pixelov pozadia. Niekedy sa prejavili aj veľmi malé zhluky pixelov pozadia, ktoré boli odstránené pri použití fuzzy mäkkého prahovania.



Obr. 11.1: Ukážka segmentácie s využitím Otsu prahovania - video č.2 (vľavo) a video č.7 (vpravo). Zdroj: vlastné.

Keďže vo finálnej podobe algoritmu bolo použité Otsu prahovanie (doplnené viacerými morfológickými operáciami), v prílohe B sú pre ukážku výsledky ďalších videí tejto metódy na rôznych segmentoch aorty.

11.1.2 Výsledky algoritmu fuzzy mäkké prahovanie

Druhým odskúšaným typom prahovania bolo fuzzy mäkké prahovanie. Od tvrdého prahovania sa líši tým, že pixely nie sú rozdelené len na triedy patrí (1) a nepatrí (0). Sú vyjadrené mierou, akou prislúcha pixel ku každej z tried. Z toho vyplýva, že každý pixel patrí do každej triedy s určitým stupňom príslušnosti v intervale $[0, 1]$. Výsledky tohto algoritmu boli veľmi dobré, pretože algoritmus dokázal potlačiť menšie nehomogenity spôsobené odleskami od aorty v obraze. Výsledky segmentácie sú zobrazené na obrázku 11.2. Vďaka priestorovej mediánovej agregácii sú oproti tvrdému prahovaniu okraje objektu taktiež viac vyhladené.



Obr. 11.2: Ukážka segmentácie metódou Fuzzy mäkkého prahovania - video č. 2 (vľavo) a video č. 7 (vpravo). Zdroj: vlastné.

11.1.3 Výsledky algoritmu metódy narastania oblastí

Tretím algoritmom je regiónovo orientovaná metóda, ktorá predpokladá určitú homogenitu segmentovaného objektu. Práve tento predpoklad môžu významne narušiť artefakty spôsobené osvetlením. V práci bola táto metóda ako jediná testovaná na všetkých troch farebných zložkách obrazu. To značne predĺžilo výpočtový čas, ale prinieslo presnejšie výsledky o zmenách v každej farebnej zložke. Metóda bola však veľmi zatažená artefaktami odleskov aorty a pri videách s väčšími miestami odleskov mala horšie výsledky ako prvé dve metódy. Pre ukážku sú zobrazené výsledky tohto algoritmu na obrázku 11.3. Z obrázkov je priamo viditeľné, že ak nastala v obraze vyššia nehomogenita, algoritmus nesprávne predpokladal hranicu a tým aj ukončenie segmentácie na danom mieste. Binárny obraz navyše obsahoval aj množstvo pixelov pozadia s hodnotou 0 v rámci objektu, čo značne znižuje úspešnosť segmentácie.



Obr. 11.3: Ukážka segmentácie metódou narastania oblastí - video č. 2 (vľavo) a video č. 7 (vpravo). Zdroj: vlastné.

11.1.4 Vplyv morfolologickej operácie uzavretie na metódu narastania oblastí

Štvrtou súčasťou komparatívnej analýzy bol experiment spojiť najhoršiu segmentáciu s morfológickou operáciou uzavretie a zhodnotiť prípadné zlepšenie. Uzavretie veľmi dobre vyplňuje nehomoge-


nity v cieve, čím významne zlepšilo hodnoty objektívnych parametrov. Táto informácia bola použitá pre vytvorenie výsledného algoritmu segmentácie.



Obr. 11.4: Ukážka segmentácie metódou narastania oblastí a morfolologickej operácie uzavretie - video č. 2 (vľavo) a video č. 7 (vpravo). Zdroj: vlastné.

11.1.5 Vyhodnotenie komparatívnej analýzy

Výsledky binárnych obrazov boli vstupom pre komparatívnu analýzu. Binárna snímka z danej metódy bola porovnaná so zlatým štandardom (manuálne vysegmentovanou snímkou). Pre každé video bolo vybratých 10 náhodných snímok z rôznych časových úsekov. Jednou formou výsledkov sú grafické ukážky 4 rôznych parametrov. Druhá forma predstavuje konkrétne hodnoty vypočítané podľa vzorcov využitých z podkapitoly 7.5. Na ukážku bolo zvolené video č. 7 z vypočítaných korelačných koeficientov jednotlivých metód:



Obr. 11.5: Výsledky korelačného koeficientu pre 4 metódy - video 7. Zdroj: vlastné

Ukážka ostatných parametrov k tomuto videu je zobrazená v prílohe A. V nasledujúcej tabuľke je zhrnutie všetkých vypočítaných parametrov (ich mediánu z 10 snímok) pre jednotlivé metódy k videu č. 1.

Tabuľka 11.1: Tabuľka parametrov komparatívnej analýzy pre video č. 1. Zdroj: vlastné.

Medián (z 10 snímok)	Otsu metóda	Metóda narastania oblastí	Metóda narastania oblastí s uzavretím	Metóda fuzzy mäkkého prahovania
Korelačný koeficient	0,9624	0,9368	0,9503	0,9627
Sorensov-Dice koeficient podobnosti	0,9751	0,9561	0,9659	0,9753
Štruktúrálna podobnosť	0,9629	0,9279	0,9610	0,9657
Stredná kvadratická chyba	0,0169	0,0285	0,0224	0,0167

Ďalšie tabuľky s rovnakými informáciami k ostávajúcim 6 videám sú v prílohe A.

11.2 Výsledný segmentačný model

Finálna podoba segmentačného modelu bola odvodená z predošlých výsledkov. Do úvahy boli vybraté viaceré kritéria ako napríklad výpočtová náročnosť. Z tohto hľadiska bolo najrýchlejším algoritmom prahovanie Otsu. Jeho rýchlosť bola až 10-násobne vyššia ako pri fuzzy prahovaní a 50-násobne rýchlejšia ako metóda narastania oblastí. Výsledky jednoznačne ukazovali na veľmi podobné hodnotenie binárnych obrazov tvrdého a mäkkého prahovania, čo vychádza z podmienok snímania. Artefakty vyskytujúce sa v obraze mali charakter väčších zhlukov pozadia v objekte a s týmto problémom si oba algoritmy poradili relatívne dobre. Metóda narastania oblastí bola ovplyvnená najviac týmto druhom šumu. Ďalším zistením bol veľmi pozitívny vplyv morfolologickej operácie uzavretie na vyplnenie nehomogenít v objekte, preto bolo zvolené aj ako súčasť výsledného algoritmu.


Presný postup a princíp jednotlivých krokov algoritmu je vysvetlený v podkapitole 7.6. Ukážka výsledkov pre všetky videá je na nasledujúcich obrázkoch:



Obr. 11.6: Ukážka výsledného segmentačného modelu - video č. 1 (vľavo) a video č. 2 (vpravo). Zdroj: vlastné.



Obr. 11.7: Ukážka výsledného segmentačného modelu - video č. 3 (vľavo) a video č. 4 (vpravo). Zdroj: vlastné.



Obr. 11.8: Ukážka výsledného segmentačného modelu - video č. 5 (vľavo) a video č. 6 (vpravo). Zdroj: vlastné.




Obr. 11.9: Ukážka výsledného segmentačného modelu - video č. 7. Zdroj: vlastné.


Morfologické operácie dokázali vyplniť väčšinu nehomogenít a dier v objekte. Výnimkou sú binárne snímky videa 5 (ľavá časť obrázku 11.8), kedy aorta obsahovala vysoký odlesk v pravej dolnej časti snímky. Avšak vzhľadom aj na ďalšie videá algoritmus vykazuje dobré výsledky a jeho robustnosť potvrdzuje segmentácia rôznorodých úsekov aorty.

11.3 Výsledky extrakcie príznakov

Základným predpokladom modelovania dynamiky umelého cievneho systému bolo, že geometrické zmeny cievy budú viditeľné v extrahovaných príznakoch ako následok pulzného toku kvapaliny v cieve. Po segmentácii sú vstupom pre extrakciu binárne obrazy rôznych segmentov aorty. Pre každé zo siedmich videí boli vypočítané 4 parametre: plocha, obvod, vlnitosť a hrúbka. Z hrúbky boli dodatočne odvodené ďalšie 2 parametre: stredná hodnota a rozptyl hrúbky objektu v čase.




Obr. 11.10: Extrahovaná plocha a obvod objektu z videa (250 snímok) - video č. 1. Zdroj: vlastné.



Obr. 11.11: Extrahovaná vlnitosť a rozptyl hrúbky objektu z videa (250 snímok) - video č. 1. Zdroj: vlastné.


Nasledujúce grafy znázorňujú 4 hlavné a 2 odvodené parametre získané extrakciou z obrazu. Výsledky tejto časti ukazujú určitý periodický charakter u väčšiny extrahovaných príznakov, ktoré popisujú mechanické vlastnosti ciev. Dynamické zmeny umelého cievneho systému korešpondujú s priebehom príznakov v čase.

Stredná hodnota hrúbky objektu v čase - video č.1



Obr. 11.12: Extrahovaná stredná hodnota hrúbky objektu z videa (250 snímok) - video č. 1. Zdroj: vlastné.

Hrúbka objektu v bode maximálnej dynamiky cievy - video č.1



Obr. 11.13: Extrahovaná hrúbka objektu z videa (250 snímok v bode, kde bola zistená najväčšia dynamika) - video č. 1. Zdroj: vlastné.

Priebeh signálov odvodených parametrov z hrúbky (rozptyl a priemer) ukazuje menej výraznú periodicitu. Predpokladám, že dôvodom je spôsob výpočtu. Priemer a rozptyl hrúbok je počítaný vo všetkých bodoch kostry objektu - takže sa do výpočtu zahrňujú aj úseky na cieve s menšou dynamikou. Oproti tomu parameter hrúbka ukazuje priebeh v určitom mieste (miesto maximálnej dynamiky) cez všetky snímky.

Ďalšie skúmanie týchto parametrov bolo vykonané porovnaním príznakov a tlakovej krivky v ďalšej podkapitole.

11.4 Výsledky korelačného algoritmu


Korelačný algoritmus bol vytvorený pre sadu dát: videozáznam, tlaková krivka a hrúbka. Ako je vysvetlené v kapitole 10 kvôli rozdielnym vzorkovacím frekvenciám boli dáta interpolované a kvôli rušeniu filtrované. Veľmi účinná bola filtrácia s využitím vlnkovej transformácie, kvôli rušeniu vyšších frekvencií ako tepová frekvencia (obrázok 10.3). Naopak na kolísanie nulovej izolínie bola využitý rozklad signálu metódou EMD a následné odstránenie najnižších pásiem ako ukazuje obrázok v kapitole vyššie 10.2. Užitočné zložky boli následne vstupom pre korelačný algoritmus.

11.4.1 Korelácia tlakovej krivky s geometrickými parametrami obrazu

Základným predpokladom korelačného algoritmu je vzťah medzi tlakovou krivkou a následnou zmenou geometrie cievy. Korelácia tu predstavuje závislosť medzi príčinou a následkom - kauzalitu (dej vyvolaný príčinou má určitý následok). Príčinou je v tomto prípade tlaková vlna, ktorá sa šíri cievou a následkom je zmena dynamiky mechanických parametrov cievy (príznaky obrazu). Bez tlakového namáhania by nenastali ani zmeny v obraze a príznaky extrahované z obrazu by boli konštantné.


Výsledky korelácie ukazujú veľmi významnú závislosť medzi tlakovou krivkou a rôznymi príznakmi z obrazu, ktoré popisujú geometriu cievy. Odkúšaných bolo 6 parametrov, ktoré hodnotili geometriu: plocha, obvod, vlnitosť, hrúbka a parametre odvodené z hrúbky: stredná hodnota hrúbky a rozptyl v čase. Ich priebeh vo videosekvencii koreloval s tlakovou krivkou, ako ukazujú obrázky 11.15, 11.16, 11.17 a 11.18.

Tlakovými senzormi boli získané v každom meraní vždy 2 tlakové krivky (ukážka na obrázku 11.14).




Obr. 11.14: Tlak meraný v odlišných miestach aorty: modrá krivka (oblúk aorty), červená krivka (zostupná časť aorty). Zdroj: vlastné.


Prvé miesto snímania tlaku bolo v aortálnom oblúku a druhé miesto v úseku zostupnej časti aorty pred rozvetvením. Medzi týmito miestami boli získané príznaky z obrazu, preto bola korelácia vytvorená s využitím oboch signálov tlaku. Ako ukazuje obrázok 11.14, tlakové krivky sú si tvarovo veľmi podobné. Rozdiel je v hodnote tlaku, ktorá smerom do periférie klesá. Hodnota tlaku nie je v rozmedzí ľudských hodnôt tlaku, pretože použitý umelý cievny systém je ekvivalentom väčšieho zvierata. Na tomto obrázku je zaznamenaných 30 sekúnd signálu s tepovou frekvenciou 60 úderov za minútu.




Obr. 11.15: Porovnanie normalizovanej tlakovej krivky a extrahovanej plochy z obrazu. Zdroj: vlastné.



Obr. 11.16: Porovnanie normalizovanej tlakovej krivky a extrahovanej hrúbky z obrazu v bode najväčšej dynamiky. Zdroj: vlastné.



Obr. 11.17: Porovnanie normalizovanej tlakovej krivky a extrahovanej vlnitosti z obrazu. Zdroj: vlastné.



Obr. 11.18: Porovnanie normalizovanej tlakovej krivky a extrahovaného obvodu z obrazu. Zdroj: vlastné.

Korelácia pre všetky príznaky z obrazu s tlakovými krivkami je zhrnutá v nasledujúcich 2 tabulkách:

Tabuľka 11.2: Tabuľka korelačných koeficientov tlakovej krivky 1 (v mieste aortálneho oblúku) a príznakov extrahovaných z obrazu. Zdroj: vlastné.

Príznak v obraze/ číslo merania	1	2	3	4	Priemerná hodnota	Mediánová hodnota
Plocha	0,9115	0,9275	0,9367	0,6779	0,8634	0,9195
Obvod	0,6239	0,7368	0,6464	0,4082	0,6038	0,6352
Vlnitosť	0,7413	0,5596	0,2102	0,2301	0,4353	0,3949
Hrúbka	0,9470	0,9282	0,9158	0,7336	0,8812	0,9220
Rozptyl hrúbky	0,1804	0,3743	0,0689	0,1292	0,1882	0,1548
Stredná hodnota hrúbky	0,1467	0,4376	0,1138	0,0902	0,1971	0,1303

Z tabuliek je evidentné, že rozdiely v korelácii sú minimálne pri porovnaní tlakovej krivky z oblúku aorty a zo zostupnej časti aorty. Vysokú koreláciu dosahujú atribúty plocha a hrúbka v mieste maximálnej dynamiky cievy. Ich priemerné korelačné koeficienty sú 0,86 a 0,88. Je vypočítaná aj mediánová hodnota, pretože ako je viditeľné z tabuľky 11.2 a 11.3, výsledky 4. merania mali vo všetkých parametroch výrazne nižší korelačný koeficient, čo negatívne ovplyvňuje priemer vypočítaných hodnôt. Strednú koreláciu vykazoval aj atribút obvod s priemernou hodnotou korelácie 0,6. Vlnitosť

Tabuľka 11.3: Tabuľka korelačných koeficientov tlakovej krivky 2 (v mieste zostupnej aorty) a príznakov extrahovaných z obrazu. Zdroj: vlastné.

Príznak v obraze/ číslo merania	1	2	3	4	Priemerná hodnota	Mediánová hodnota
Plocha	0,9094	0,9242	0,9384	0,6735	0,8614	0,9168
Obvod	0,6253	0,7360	0,6551	0,4042	0,6051	0,6402
Vlnitosť	0,7363	0,5623	0,2109	0,2174	0,4317	0,3898
Hrúbka	0,9454	0,9252	0,9186	0,7315	0,8802	0,9219
Rozptyl hrúbky	0,1882	0,3757	0,0674	0,1263	0,1894	0,1573
Stredná hodnota hrúbky	0,1558	0,4346	0,1102	0,0893	0,1975	0,1330


má síce priemerne nižšiu koreláciu - iba 0,43, avšak vzhľadom na hodnoty z prvých dvoch meraní je možné vyvodzovať závislosť výslednej korelácie od tepovej frekvencie. Priemer korelačných koeficientov z prvých 2 meraní, kedy bola tepová frekvencia 60 úderov za minútu, je 0,65. V kontraste k tomu výsledný priemer korelácie 3. a 4. merania (120 tepov za minútu) činí len 0,22, čo je interpretované ako nie príliš tesný vzťah. Pre úplné verenie by bolo potrebné nasnímať záznamy pri tepových frekvenciách s menším krokom v rozmedzí 0,5 Hz až 2 Hz. V tejto práci bolo porovnanie frekvencií 1 Hz a 2 Hz.

11.4.2 Korelácia hrúbky (externý senzor) s geometrickým parametrom hrúbka objektu (video)

V práci bola vytvorená korelácia medzi extrahovaným príznakom hrúbky cievy a nasnímanou hrúbkou z optického senzoru. Dáta získané z optického senzoru boli predspracované s využitím vlnkovej transformácie. Stupeň dekompozície bol nastavený na hodnotu 6 a použitá vlnka bola *db5* (podľa analýz v kapitole 10). Nasledujúci graf ukazuje filtrované dáta hrúbky v 4 meraniach. Prvé dve snímali cievu s tepovou frekvenciou 60 tepov za minútu a tretie a štvrté meranie s tepovou frekvenciou 120 tepov za minútu. Ich ukážka je zobrazená v grafe 11.19.

Výsledky korelačných koeficientov medzi hrúbkou z obrazu a hrúbkou z externého senzoru zahŕňa tabuľka 11.4. Grafickou ukážkou sú výsledky zobrazené na obrázku 11.20. Tento graf je vytvorený z prvého merania.


Hodnoty korelačných koeficientov predstavujú určité overenie algoritmu extrakcie hrúbky cievy z obrazu. Je viditeľné, že pri snímaní cievy z väčšej vzdialenosti korelujú tieto hodnoty s koeficientom nad 0,9 - teda významná korelácia. Pri videách, ktoré zaznamenávajú cievu detailnejšie je miera závislosti o niečo nižšia, no stále podstatná. Týmito hodnotami boli overené extrakcie hrúbky pri podmienkach frekvencie 1 Hz (60 tepov za minútu) aj frekvencie 2 Hz (120 tepov za minútu). Taktiež je dôležité poznamenať, že merania boli vykonané v navzájom kolmých rovinách. V jednej rovine bol získaný videozáznam a v druhej hrúbka v milimetroch.



Obr. 11.19: Vykreslenie filtrovaných signálov opticky zmeranej hrúbky v 4 meraniach na rovnakom segmente aorty. Zdroj: vlastné.

Tabuľka 11.4: Tabuľka korelačných koeficientov medzi hrúbkami cievy nasnímanými opticky a videozáznamom. Zdroj: vlastné.


Meranie	Tepová frekvencia (počet úderov/minúta)	Typ videa	Korelačný koeficient (opticky zmeraná hrúbka a extrahovaná hrúbka z obrazu)
1	60	prehľadová snímka	0,9244
2	60	detail	0,8329
3	120	prehľadová snímka	0,9115
4	120	detail	0,7280



Obr. 11.20: Porovnanie normalizovaných signálov hrúbky z videa a optického senzora. Zdroj: vlastné.

11.4.3 Vplyv fixácie cievy na extrahované príznaky

Keďže boli pri druhej sade dát použité aj externé senzory, bolo nutné časť snímanej aorty fixovať. Fixácia bola dôležitá hlavne kvôli optickému senzoru a dodržaniu definovaných vzdialeností (viac v kapitole 6). Porovnaním extrahovaných príznakov rovnakého segmentu aorty (zostupnej časti) s fixáciou a bez fixácie, je viditeľný veľký vplyv fixácie na stálosť signálu. Taktiež je vďaka fixácii potlačený vplyv RBM popísaný v kapitole 10. Grafické porovnanie extrahovanej plochy je na obrázku 11.21.



Obr. 11.21: Extrahovaná plocha z obrazu s fixáciou a bez fixácie snímanej aorty. Zdroj: vlastné.

Kapitola 12

Záver

Táto diplomová práca sa zaoberá modelovaním a kvantitatívnou analýzou dynamiky mechanických vlastností cievneho systému. Jedným z cieľov práce bolo vytvorenie optimálneho segmentačného modelu, ktorý umožní sledovať cievny systém z videozáznamu. Následne boli implementované algoritmy pre extrakciu geometrických parametrov z obrazu a koreláciu týchto parametrov s tlakovým namáhaním.

Súčasťou práce bola realizácia experimentálnych meraní na umelom modeli krvného riečiska. V prvej sade meraní bolo nasnímaných 7 videozáznamov rôznych segmentov aorty. V druhom meraní boli súbežne zaznamenané 3 druhý dát: video, tlaková krivka a hrúbka aorty. Videozáznamy boli rozčlenené na snímky pre ďalšie spracovanie.

Základom pre analýzu obrazu bol výber vhodného segmentačného algoritmu. Voľba metódy je objektívne posúdená z hľadiska rôznych parametrov v rámci komparatívnej analýzy daných metód. Použité parametre objektívneho hodnotenia kvality obrazu boli korelačný koeficient, Sorensov-Dice koeficient, koeficient štruktúrálnej podobnosti a stredná kvadratická chyba. Porovnávané boli segmentácie s využitím Otsu prahovania, fuzzy mäkkého prahovania a metódy narastania oblastí. Z výsledkov porovnávacej analýzy bol odvodený výsledný segmentačný model, ktorý používal Otsu prahovanie. Algoritmus bol doplnený morfológickými operáciami pre odstránenie artefaktov spôsobených odleskami z aorty, ktoré prahovanie nedokázalo správne vyhodnotiť. Informácia o farbe objektu bola využitá v procese spracovania, pretože najväčšie jasové rozdiely medzi objektom a pozadím boli v modrej farebnej zložke obrazu.

Ďalším cieľom práce bola implementácia algoritmov pre extrakciu príznakov z obrazu. Pomocou týchto geometrických parametrov je možné kvantifikovať objekt v obraze – v tomto prípade aortu v konkrétnom čase. Pre každé video boli vypočítané 4 hlavné parametre: plocha, obvod, vlnitosť a hrúbka. Z hrúbky boli odvodené 2 vedľajšie: stredná hodnota a rozptyl hrúbky objektu v čase. Pre extrakciu vlnitosti a hrúbky bola použitá tzv. skeletonizácia obrazu, distančná mapa a detekcia koncových bodov. Výsledky tejto časti ukazujú určitý periodický charakter u väčšiny extrahova-

ných príznakov, ktoré popisujú mechanické vlastnosti ciev. Na demonštrovanie funkcionality týchto modulov práce bolo vytvorené grafické užívateľské prostredie v Matlabe.

Tretím cieľom bola realizácia korelačného algoritmu medzi extrahovanými príznakmi a tlakovou vlnou. Korelácia v tomto prípade predstavuje závislosť medzi príčinou a následkom. Príčinou je tlaková vlna, ktorá sa šíri cievou a následkom je zmena dynamiky mechanických parametrov cievy. Výsledky korelácie ukazujú rôzne závislosti vzhľadom na konkrétny geometrický parameter. Strednú koreláciu vykazuje obvod a vlnitosť s hodnotou 0,6 a 0,65. V prípade vlnitosti bol výsledok značne ovplyvnený tepovou frekvenciou. Hodnoty korelačného koeficientu pri 60 úderoch za minútu boli trojnásobne vyššie ako hodnoty pri 120 úderoch za minútu. Významnú koreláciu dosahuje plocha a hrúbka v mieste maximálnej dynamiky cievy s koreláciou 0,86 a 0,88. Na záver bola pre overenie funkčnosti algoritmu detekcie hrúbky analyzovaná korelácia medzi výsledkami extrakcie hrúbky a hrúbkou zmeranou externým senzorom. Priemerný korelačný koeficient s hodnotou 0,86 potvrdzuje správne vyhodnotenie implementovaného algoritmu. Pri snímaní cievy z väčšej vzdialenosti dosahuje korelácia hodnoty nad 0,9. Pri menšej vzdialenosti bol dosiahnutý nižší korelačný koeficient (približne 0,78). Dôvodom môže byť, že pri detailnejšej snímke sú v obraze väčšie plochy nechcených artefaktov, čo môže ovplyvniť kvalitu segmentácie aj extrakcie príznakov.

Umelý cievny systém je veľmi dobrým základom pre neinvazívne merania a hľadanie závislostí medzi dynamikou vlastností ciev a tlakovým namáhaním. Výsledky tejto práce udávajú určitý podklad a závery, že vzťah medzi tlakovým namáhaním a extrahovanou geometriou cievy z videozáznamu je pri daných podmienkach zreteľný. Novým skúmaným parametrom v tejto oblasti je vlnitosť cievy ako miera globálneho zakrivenia. Vlnitosť je v mnohých prácach skúmaná v kontexte kolagénových vlákien v cieve, avšak výsledky tejto práce ukazujú aj na možnosti v oblasti skúmania vlnitosti celej cievy. Extrakcia parametrov objektu je výrazne závislá od správnej segmentácie. Z tohto dôvodu predpokladám, že pre zdokonalenie metód by mohlo byť vhodné realizovať ďalšie merania zamerané na rôzne svetelné podmienky a vzdialenosti snímania. Taktiež je tu priestor pre ďalšie možnosti v rámci spracovania záznamov reálnych zobrazovacích metód a vytvorenie segmentačných modelov aorty vhodných aj pre RTG a USG. V rámci diagnostiky je čím ďalej, tým väčší trend nositeľných zariadení a bezkontaktných meraní, preto môže v budúcnosti oblasť tohto výskumu viesť napríklad aj k bezkontaktnému meraniu parametrov reálneho cievneho systému.

Literatúra

1. *Cardiovascular Diseases* [online] [cit. 2020-11-12]. Dostupné z: https://www.who.int/health-topics/cardiovascular-diseases/#tab=tab_1.
2. KLABUNDE, Richard E. *Cardiovascular physiology concepts*. 2. vyd. Philadelphia, PA: Lippincott Williams a Wilkins/Wolters Kluwer, 2012. ISBN 978-1-4511-1384-6.
3. KITTNAR, Otomar. *Lékařská fyziologie*. Praha: Grada Publishing, 2011. ISBN 978-80-247-3068-4.
4. *Anatomy of the Heart* [online]. Queensland Cardiovascular Group [cit. 2020-11-12]. Dostupné z: <https://qcg.com.au/patients/anatomy-heart>.
5. JAVORKA, Kamil. *Fyziológia: učebnica pre lekárske fakulty*. Martin: Osveta, 2009. ISBN 978-80-8063-291-5.
6. GANONG, William F. *Přehled lékařské fyziologie: dvacáté vydání*. Praha: Galén, 2005. ISBN 80-726-2311-7.
7. KLABUNDE, Richard E. *Vascular Compliance* [online]. Cardiovascular Physiology Concepts [cit. 2020-11-12]. Dostupné z: <https://www.cvphysiology.com/Blood%5C%20Pressure/BP004>.
8. *Kardiovaskulární systém* [online]. MUNI [cit. 2020-11-12]. Dostupné z: https://is.muni.cz/el/med/podzim2014/VSHE0322c/um/09-Kardiovaskularni_system_-_CZE.pdf?lang=en.
9. ČAPEK Lukáš, Petr HÁJEK a Petr HENYŠ. *Biomechanika člověka*. Praha: Grada Publishing, 2018. ISBN 978-80-271-0367-6.
10. MICHAEL F. O'ROURKE, Alfredo PAUCA a Xiong-Jing JIANG. Pulse wave analysis. *British Journal of Clinical Pharmacology* [online]. 2001, roč. 51, č. 6, s. 507–522 [cit. 2020-11-12]. ISSN 03065251. Dostupné z DOI: 10.1046/j.0306-5251.2001.01400.x.
11. PENHAKER, Marek. *Lékařské diagnostické přístroje: učební texty*. Ostrava: VŠB - Technická univerzita Ostrava, 2004. ISBN 80-248-0751-3.
12. BINDER, Svatopluk. *Průběh pulsní vlny v závislosti na elasticitě cévního systému na arteria radialis* [online]. 2009. Dostupné tiež z: <https://theses.cz/id/i69cnp>. Disertační práce. Univerzita Palackého v Olomouci, Lékařská fakulta, Olomouc. Vedúci práce Jan HÁLEK.

13. SALVI Paolo, Antonio BELLASI a Biagio DI IORIO. Does It Make Sense to Measure Only the Brachial Blood Pressure? *Blood Purification* [online]. 2013, roč. 36, č. 1, s. 21–25 [cit. 2020-11-12]. ISSN 1421-9735. Dostupné z DOI: 10.1159/000350581.
14. CHARLTON, Peter H. et al. Modeling arterial pulse waves in healthy aging: a database for in silico evaluation of hemodynamics and pulse wave indexes. *American Journal of Physiology-Heart and Circulatory Physiology* [online]. 2019, roč. 317, č. 5 [cit. 2020-11-12]. ISSN 0363-6135. Dostupné z DOI: 10.1152/ajpheart.00218.2019.
15. SALVI, Paolo. *Pulse Waves: How Vascular Hemodynamics Affects Blood Pressure*. 2. vyd. Cham: Springer International Publishing, 2017. ISBN 978-3-319-40501-8.
16. SALVI, Paolo a Gianfranco PARATI. Aortic stiffness and myocardial ischemia. *Journal of Hypertension* [online]. 2015, roč. 33, č. 9, s. 1767–1771 [cit. 2020-11-12]. ISSN 0263-6352. Dostupné z DOI: 10.1097/HJH.0000000000000706.
17. GOUDARZI, Reza Heydari et al. Using imaging Photoplethysmography (iPPG) Signal for Blood Pressure Estimation. In: *2020 International Conference on Machine Vision and Image Processing (MVIP)* [online]. 2020, s. 1–6 [cit. 2020-11-12]. ISBN 978-1-7281-6832-6. Dostupné z DOI: 10.1109/MVIP49855.2020.9116902.
18. BABBS, Charles F. Oscillometric measurement of systolic and diastolic blood pressures validated in a physiologic mathematical model. *BioMedical Engineering OnLine* [online]. 2012, roč. 11, č. 1 [cit. 2020-11-12]. ISSN 1475-925X. Dostupné z DOI: 10.1186/1475-925X-11-56.
19. JAIN Monika, Sujay DEB; SUBRAMANYAM, A. V. Face video based touchless blood pressure and heart rate estimation. In: *2016 IEEE 18th International Workshop on Multimedia Signal Processing (MMSP)* [online]. 2016, s. 1–5 [cit. 2020-11-12]. ISBN 978-1-5090-3724-7. Dostupné z DOI: 10.1109/MMSP.2016.7813389.
20. SHAO, Dangdang et al. Non-Contact Simultaneous Photoplethysmogram and Ballistocardiogram Video Recording towards Real-Time Blood Pressure and Abnormal Heart Rhythm Monitoring. In: *2017 12th IEEE International Conference on Automatic Face Gesture Recognition (FG 2017)* [online]. 2017, s. 273–277 [cit. 2020-11-12]. ISBN 978-1-5090-4023-0. Dostupné z DOI: 10.1109/FG.2017.42.
21. ALLEN, John et al. Photoplethysmography Assessments in Cardiovascular Disease. *Measurement and Control* [online]. 2006, roč. 39, č. 3, s. 80–83 [cit. 2020-11-12]. ISSN 0020-2940. Dostupné z DOI: 10.1177/002029400603900303.
22. SUN, Yu et al. Photoplethysmography Revisited: From Contact to Noncontact, From Point to Imaging. *IEEE Transactions on Biomedical Engineering* [online]. 2016, roč. 63, č. 3, s. 463–477 [cit. 2020-11-12]. ISSN 0018-9294. Dostupné z DOI: 10.1109/TBME.2015.2476337.

23. GHAMARI, Mohammad et al. A review on wearable photoplethysmography sensors and their potential future applications in health care. *International journal of biosensors bioelectronics* [online]. 2018, roč. 4, č. 4, s. 195–202 [cit. 2020-11-12]. ISSN 25732838. Dostupné z DOI: 10.15406/ijbsbe.2018.04.00125.
24. *Monitor your heart rate with Apple Watch* [online]. Apple, 2021 [cit. 2020-11-12]. Dostupné z: <https://support.apple.com/en-us/HT204666>.
25. LAI, Marco et al. Perfusion Monitoring by Contactless Photoplethysmography Imaging. In: *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)* [online]. 2019, s. 1778–1782 [cit. 2020-11-12]. ISBN 978-1-5386-3641-1. Dostupné z DOI: 10.1109/ISBI.2019.8759547.
26. LEE, Kanghyu et al. Video-Based Contactless Heart-Rate Detection and Counting via Joint Blind Source Separation with Adaptive Noise Canceller. *Applied Sciences* [online]. 2019, roč. 9, č. 20 [cit. 2020-11-12]. ISSN 2076-3417. Dostupné z DOI: 10.3390/app920434.
27. HSU YungChien, Yen-Liang LIN a Winston HSU. Learning-based heart rate detection from remote photoplethysmography features. In: *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* [online]. 2014, s. 4433–4437 [cit. 2020-11-12]. Dostupné z DOI: 10.1109/ICASSP.2014.6854440.
28. VAN DER KOOIJ, Koen M. a Marnix NABER. An open-source remote heart rate imaging method with practical apparatus and algorithms. *Behavior Research Methods* [online]. 2019, roč. 51, č. 5, s. 2106–2119 [cit. 2020-11-12]. ISSN 1554-3528. Dostupné z DOI: 10.3758/s13428-019-01256-8.
29. TANAKA Akira, Misaki KUMAGAI a Makoto YOSHIKAWA. Non-contact Assessment of Peripheral Hemodynamics by Using Video Plethysmography. In: *2019 IEEE 8th Global Conference on Consumer Electronics (GCCE)* [online]. 2019, s. 131–133 [cit. 2020-11-12]. ISBN 978-1-7281-3575-5. Dostupné z DOI: 10.1109/GCCE46687.2019.9015559.
30. GUZMAN Jairo Hernandez, Jean-Philippe COUDERC a Gill R. TSOURI. Accurate Hemodynamic Sensing using Video Plethysmography with High Quality Cameras. In: *2019 13th International Symposium on Medical Information and Communication Technology (ISMICT)* [online]. 2019, s. 1–6 [cit. 2020-11-12]. ISBN 978-1-7281-2342-4. Dostupné z DOI: 10.1109/ISMICT.2019.8743955.
31. KONG, LingQin et al. Robust Imaging Photoplethysmography in Long-Distance Motion. *IEEE Photonics Journal* [online]. 2020, roč. 12, č. 3, s. 1–12 [cit. 2020-11-12]. ISSN 1943-0655. Dostupné z DOI: 10.1109/JPHOT.2020.2995397.
32. ZHOU, Yimin et al. The Noninvasive Blood Pressure Measurement Based on Facial Images Processing. *IEEE Sensors Journal* [online]. 2019, roč. 19, č. 22, s. 10624–10634 [cit. 2020-11-12]. ISSN 1530-437X. Dostupné z DOI: 10.1109/JSEN.2019.2931775.

33. DOUGHERTY, Geoff. *Pattern recognition and classification*. New York: Springer, 2013. ISBN 978-146-1453-222.
34. TOMORI, Zoltán a Matej NIKOROVIČ. *Počítačové videnie v praxi* [online]. Košice: Ústav experimentálnej fyziky SAV, 2016 [cit. 2020-11-12].
35. HORÁK, Karel. *Popis objektů* [online]. Computer Vision Group [cit. 2020-11-12]. Dostupné z: http://vision.uamt.feec.vutbr.cz/P0V/lectures/08_Popis_objektu.pdf.
36. MILAN Sonka, Vaclav HLAVAC a Roger BOYLE. *Image Processing, Analysis, and Machine Vision*. 4. vyd. Stamford: Cengage Learning, 2015. ISBN 978-1-133-59360-7.
37. PETER, Lukáš. *Model guided improvements in the measurement of continuous non invasive blood pressure*. Ostrava, 2017. Dostupné tiež z: <http://hdl.handle.net/10084/127354>. Disertační práce. Vysoká škola báňská - Technická univerzita Ostrava.
38. BARVÍK, Daniel. *Senzorika pro měření parametrů modelu krevního řečiště*. Ostrava, 2019. Dostupné tiež z: <https://dspace.vsb.cz/handle/10084/136194>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
39. *Argon Product Catalog 2013* [online]. Argon Medical Devices, 2013 [cit. 2021-04-03]. Dostupné z: <https://kategorizacia.mzsr.sk/Pomocky/Download/RequestAttachment/48658>.
40. *IG řada uživatelská příručka* [online]. Keyence, 2010 [cit. 2021-04-03]. Dostupné z: <https://www.keyence.eu/cscz/mykeyence/?ptn=001%5C&dlLangId=%5C&dlLangType=en-GB>.
41. MICHAL, Španěl. *Obrazové segmentační techniky: Přehled existujících metod* [online]. Ústav Počítačové grafiky a multimédií [cit. 2021-04-04]. Dostupné z: <http://www.fit.vutbr.cz/~spanel/segmentace/>.
42. OTSU, N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics* [online]. 1979, roč. 9, č. 1, s. 62–66 [cit. 2021-04-04]. ISSN 2168-2909. Dostupné z DOI: 10.1109/TSMC.1979.4310076.
43. GREENSTED, Andrew. *Otsu Thresholding* [online]. The Lab Book Pages, 2010 [cit. 2021-04-04]. Dostupné z: <http://www.labbookpages.co.uk/software/imgProc/otsuThreshold.html>.
44. BIRDAL, Tolga. *Famous Otsu Thresholding in C#* [online]. CodeProject [cit. 2021-04-04]. Dostupné z: <https://www.codeproject.com/Articles/38319/Famous-Otsu-Thresholding-in-C>.
45. RONZHINA, Marina. *Prednášky z predmetu AUIN*. Vysoké učení technické v Brně, 2018.
46. AJA-FERNÁNDEZ Santiago, Ariel Hernán CURIALE a Gonzalo VEGAS-SÁNCHEZ-FERRERO. A local fuzzy thresholding methodology for multiregion image segmentation. *Knowledge-Based Systems*. 2015, roč. 83, s. 1–12. ISSN 0950-7051. Dostupné z DOI: <https://doi.org/10.1016/j.knosys.2015.02.029>.

47. *Trapezoidal membership function* [online]. Mathworks [cit. 2021-04-14]. Dostupné z: <https://www.mathworks.com/help/fuzzy/trapmf.html>.
48. WALEK Petr, Martin LAMOŠ a Jiří JAN. *Analýza biomedicínských obrazů počítačová cvičení FEKT VUT v Brně* [online]. Brno: Ustav biomedicínského inženýrství, 2015 [cit. 2020-11-12]. ISBN 978-80-214-4792-9.
49. MONCADA-TORRES, Arturo. *Generating a Binary Mask* [online]. Github, 2019 [cit. 2021-04-12]. Dostupné z: <https://github.com/arturomoncadatorres/generating-binary-mask/tree/master/matlab>.
50. LANE, David M. *Introduction to Statistics* [online]. Rice University, 2003 [cit. 2021-04-07]. Dostupné z: https://onlinestatbook.com/Online_Statistics_Education.pdf.
51. *Korelační a regresní analýza* [online]. MUNI, 2011 [cit. 2021-04-07]. Dostupné z: <https://is.muni.cz/el/1423/podzim2011/SPR132/um/27576871/27576997/predn9.pdf?lang=en>.
52. MOHAMADI Pedram, Abbas EBRAHIMI-MOGHADAM a Shahram SHIRANI. Subjective and Objective Quality Assessment of Image: A Survey. *Majlesi Journal of Electrical Engineering* [online]. 2015, roč. 9, č. 1 [cit. 2021-04-07]. Dostupné z: <https://profdoc.um.ac.ir/articles/a/1048833.pdf>.
53. INSTEPANIAN, R. S. H. et al. Subjective and objective quality assessment in wireless teleultrasonography imaging. In: *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2008, s. 5346–5349. Dostupné z DOI: 10.1109/IEMBS.2008.4650422.
54. MEHRA, Rajesh. Estimation of the Image Quality under Different Distortions. *International Journal Of Engineering And Computer Science* [online]. 2016-07-19 [cit. 2021-04-07]. ISSN 23197242. Dostupné z DOI: 10.18535/ijecs/v5i7.20.
55. VERMA, Vijay a Rajesh Kumar AGGARWAL. A comparative analysis of similarity measures akin to the Jaccard index in collaborative recommendations: empirical and theoretical perspective. *Social Network Analysis and Mining* [online]. 2020, roč. 10, č. 1 [cit. 2021-04-07]. ISSN 1869-5450. Dostupné z DOI: 10.1007/s13278-020-00660-9.
56. SARA Umme, Morium AKTER a Mohammad Shorif UDDIN. Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study. *Journal of Computer and Communications* [online]. 2019, roč. 07, č. 03, s. 8–18 [cit. 2021-04-07]. ISSN 2327-5219. Dostupné z DOI: 10.4236/jcc.2019.73002.
57. NOVÁK, Kamil. *Analýza vlivu uspořádání kolagenu na mechanické vlastnosti tepen* [online]. 2018. Dostupné tiež z: <https://dspace.vutbr.cz/xmlui/handle/11012/84050>. Disertační práce. Vysoké učení technické v Brně.

58. STANKE, Ladislav et al. Towards to Optimal Wavelet Denoising Scheme—A Novel Spatial and Volumetric Mapping of Wavelet-Based Biomedical Data Smoothing. *Sensors*. 2020, roč. 20, č. 18. ISSN 1424-8220. Dostupné z DOI: 10.3390/s20185301.
59. SAURABAH, Pal a Madhuchhanda MITRA. Empirical mode decomposition based ECG enhancement and QRS detection. *Computers in Biology and Medicine*. 2012, roč. 42, č. 1, s. 83–92. ISSN 0010-4825. Dostupné z DOI: <https://doi.org/10.1016/j.compbiomed.2011.10.012>.
60. *Standard deviation* [online]. Mathworks [cit. 2021-04-12]. Dostupné z: <https://www.mathworks.com/help/matlab/ref/std.html>.

Zoznam príloh

Dodatok A: Výsledky komparatívnej analýzy

Dodatok B: Výsledky segmentácie pri komparatívnej analýze - Otsu prahovanie

Dodatok C: Grafické užívateľské rozhranie

Príloha v IS EDISON

- Zložka Kody__algortimy - obsahuje všetky skripty a funkcie použité v tejto diplomovej práci
- Zložka Vysledky - obsahuje výsledky segmentácie a extrakcie príznakov
- Zložka GUI - obsahuje grafické užívateľské rozhranie s ukážkou videa 1

Kompletné elektronické prílohy


Dostupné z: [https://www.dropbox.com/s/77b6mehhzl60ukt/2021_BAB0104_DP_priloha.zip?dl=](https://www.dropbox.com/s/77b6mehhzl60ukt/2021_BAB0104_DP_priloha.zip?dl=0)

0. Prílohy obsahujú nasledujúce zložky:

- Raw_Data - obsahuje všetky nasmiňané dáta (videozáznamy, tlak, hrúbka)
- Comparative_analysis - obsahuje kódy a výsledky komparatívnej analýzy
- Result_segmentation - obsahuje kódy a výsledky finálneho segmentačného modelu cievy
- Result_features - obsahuje kódy a výsledky extrakcie príznakov
- Correlation_pressure_features - obsahuje korelačný algoritmus, funkcie pre koreláciu tlaku s extrahovanými príznakmi
- GUI - obsahuje grafické užívateľské rozhranie

Dodatok A


Výsledky komparatívnej analýzy




Obr. A.1: Výsledky Sorensov-Dice koeficientu pre 4 metódy - video 7. Zdroj: vlastné

Tabuľka A.1: Tabuľka parametrov komparatívnej analýzy pre video č. 2. Zdroj: vlastné.

Medián (z 10 snímiek)	Metóda 1	Metóda 2	Metóda 3	Metóda 4
CORR	0,9511	0,9239	0,9344	0,9516
DICE	0,9669	0,9473	0,9544	0,9672
SSIM	0,9462	0,9290	0,9479	0,9506
MSE	0,0215	0,0035	0,0291	0,0212



Obr. A.2: Výsledky koeficientu štruktúrálnej podobnosti pre 4 metódy - video 7. Zdroj: vlastné



Obr. A.3: Výsledky strednej kvadratickej chyby pre 4 metódy - video 7. Zdroj: vlastné

Tabuľka A.2: Tabuľka parametrov komparatívnej analýzy pre video č. 3. Zdroj: vlastné.

Medián (z 10 snímiek)	Metóda 1	Metóda 2	Metóda 3	Metóda 4
CORR	0,9549	0,9422	0,9519	0,9536
DICE	0,9700	0,9596	0,9667	0,9691
SSIM	0,9591	0,9399	0,9624	0,9615
MSE	0,0202	0,0257	0,0214	0,0208

Tabuľka A.3: Tabuľka parametrov komparatívnej analýzy pre video č. 4. Zdroj: vlastné.

Medián (z 10 snímiek)	Metóda 1	Metóda 2	Metóda 3	Metóda 4
CORR	0,8427	0,7188	0,7574	0,8431
DICE	0,9364	0,8385	0,8675	0,9365
SSIM	0,8926	0,7825	0,8409	0,8962
MSE	0,0760	0,1632	0,1374	0,0758

Tabuľka A.4: Tabuľka parametrov komparatívnej analýzy pre video č. 5. Zdroj: vlastné.

Medián (z 10 snímiek)	Metóda 1	Metóda 2	Metóda 3	Metóda 4
CORR	0,7670	0,5314	0,5805	0,7269
DICE	0,9516	0,8256	0,8593	0,9501
SSIM	0,8837	0,6468	0,7747	0,8909
MSE	0,0778	0,2477	0,2056	0,0818

Tabuľka A.5: Tabuľka parametrov komparatívnej analýzy pre video č. 6. Zdroj: vlastné.

Medián (z 10 snímiek)	Metóda 1	Metóda 2	Metóda 3	Metóda 4
CORR	0,8711	0,6733	0,7282	0,8655
DICE	0,9347	0,7702	0,8210	0,9319
SSIM	0,9088	0,7232	0,8309	0,9117
MSE	0,0665	0,1836	0,1497	0,0698

Tabuľka A.6: Tabuľka parametrov komparatívnej analýzy pre video č. 7. Zdroj: vlastné.

Medián (z 10 snímiek)	Metóda 1	Metóda 2	Metóda 3	Metóda 4
CORR	0,9372	0,8824	0,9252	0,9373
DICE	0,9678	0,9322	0,9593	0,9679
SSIM	0,9416	0,8762	0,9427	0,9461
MSE	0,0314	0,0618	0,0383	0,0313

Dodatok B

Výsledky segmentácie pri komparatívnej analýze - Otsu prahovanie



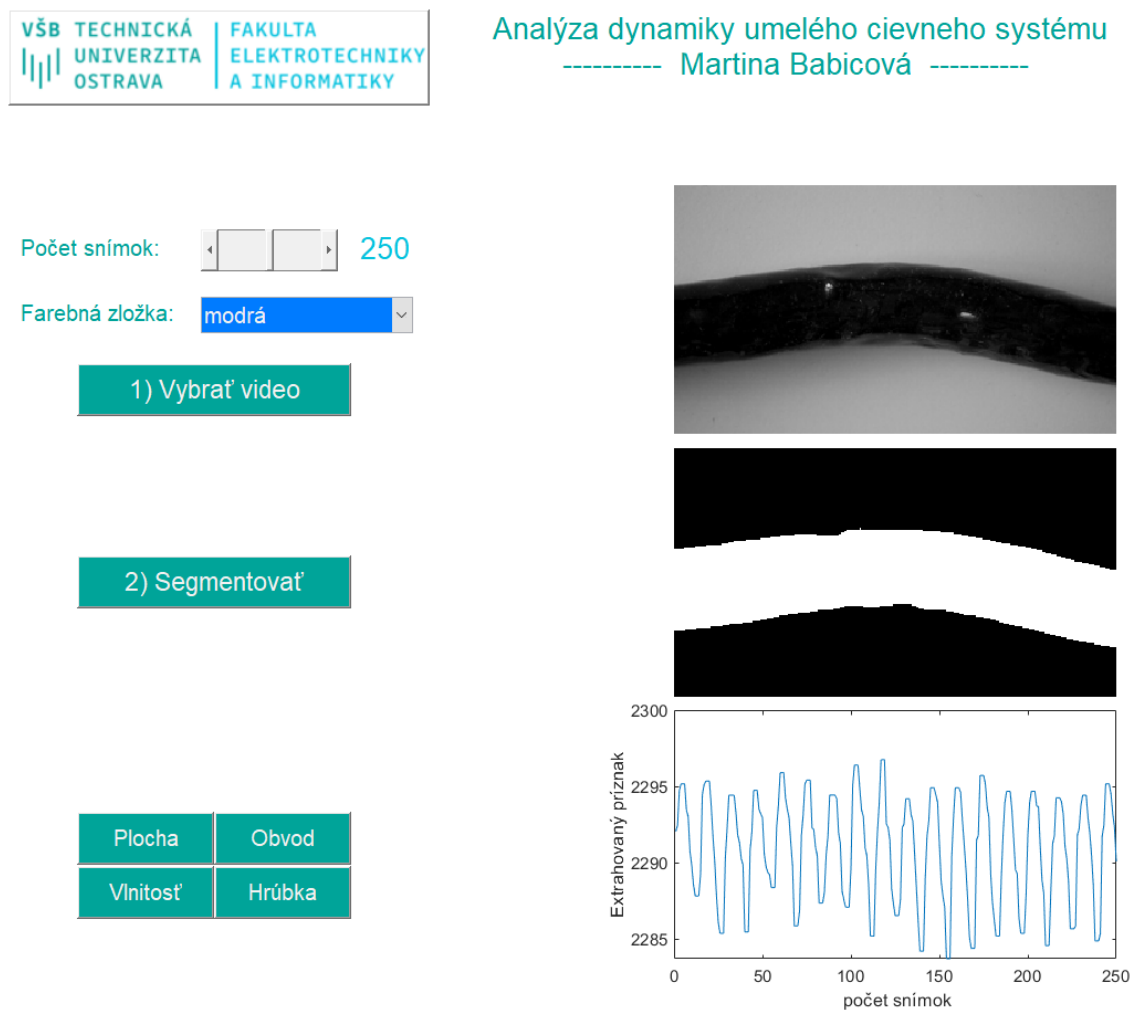
Obr. B.1: Ukážka segmentácie s využitím Otsu prahovania - video č. 3 (vľavo) a video č. 4 (vpravo).
Zdroj: vlastné.



Obr. B.2: Ukážka segmentácie s využitím Otsu prahovania - video č. 5 (vľavo) a video č. 6 (vpravo).
Zdroj: vlastné.

Dodatok C

Grafické užívateľské rozhranie



Obr. C.1: Grafické užívateľské rozhranie analýzy umelého cievneho systému. Zdroj: vlastné.